



VICERRECTORADO ACADÉMICO
ESCUELA DE POSGRADO

TESIS

**MODELO DEEP LEARNING EN EL SISTEMA DE SELECCIÓN
DE CONTRATISTAS EN EL SECTOR MINERO, TACNA 2023**

PRESENTADO POR:

Mg. JUAN CARLOS JIMENEZ FLORES
(ORCID: 0000-0002-3793-3563)

LINEA DE INVESTIGACION

**GESTIÓN, INNOVACIÓN, INFRAESTRUCTURA, TECNOLOGÍA Y
MEDIO AMBIENTE**

**PARA OPTAR EL GRADO ACADÉMICO DE:
DOCTOR EN INGENIERÍA DE SISTEMAS**

ASESOR:

Dr. RAFAEL RUTTE, ROBERT RICHARD
(ORCID: 0000-0003-2411-0223)

LIMA - PERÚ

2023

MODELO DEEP LEARNING EN EL SISTEMA DE SELECCIÓN DE CONTRATISTAS EN EL SECTOR MINERO, TACNA 2023

INFORME DE ORIGINALIDAD

13%	13%	3%	4%
INDICE DE SIMILITUD	FUENTES DE INTERNET	PUBLICACIONES	TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1	repositorio.uap.edu.pe Fuente de Internet	3%
2	repositorio.ucv.edu.pe Fuente de Internet	3%
3	Submitted to Universidad Nacional Federico Villarreal Trabajo del estudiante	1%
4	renati.sunedu.gob.pe Fuente de Internet	<1%
5	www.repositorio.upla.edu.pe Fuente de Internet	<1%
6	bdigital.unal.edu.co Fuente de Internet	<1%
7	revistas.urp.edu.pe Fuente de Internet	<1%
8	repositorio.upla.edu.pe Fuente de Internet	<1%

9	repositorio.continental.edu.pe Fuente de Internet	<1 %
10	repositorio.unsa.edu.pe Fuente de Internet	<1 %
11	Submitted to Universidad Tecnológica Centroamericana UNITEC Trabajo del estudiante	<1 %
12	repositorio.upt.edu.pe Fuente de Internet	<1 %
13	apirepositorio.unh.edu.pe Fuente de Internet	<1 %
14	es.slideshare.net Fuente de Internet	<1 %
15	www.researchgate.net Fuente de Internet	<1 %
16	plataforma.responsable.net Fuente de Internet	<1 %
17	repositorioacademico.upc.edu.pe Fuente de Internet	<1 %
18	www.congresobc.gob.mx Fuente de Internet	<1 %
19	repositorio-digital.cide.edu Fuente de Internet	<1 %
20	fddocuments.es	

Fuente de Internet

<1 %

21

Submitted to uncedu

Trabajo del estudiante

<1 %

22

luisdoubrontgschool.files.wordpress.com

Fuente de Internet

<1 %

23

www.mediummultimedia.com

Fuente de Internet

<1 %

24

biblioteca2.ucab.edu.ve

Fuente de Internet

<1 %

25

vsip.info

Fuente de Internet

<1 %

26

repositorio.ucss.edu.pe

Fuente de Internet

<1 %

27

www.goconqr.com

Fuente de Internet

<1 %

28

www.slideshare.net

Fuente de Internet

<1 %

29

repositorio.unu.edu.pe

Fuente de Internet

<1 %

30

www.kiwa.com

Fuente de Internet

<1 %

31

biblioteca.uteg.edu.ec

Fuente de Internet

<1 %

32	cybertesis.unmsm.edu.pe Fuente de Internet	<1 %
33	doku.pub Fuente de Internet	<1 %
34	hdl.handle.net Fuente de Internet	<1 %
35	Orlando Vásquez Álvarez, Pedro Pablo Rosales López. "Application of a discrete simulation model to improve the productivity of the production process in a manufacturing company", Industrial Data, 2023 Publicación	<1 %
36	noticiasonline2020.com Fuente de Internet	<1 %
37	www.aulavirtualusmp.pe Fuente de Internet	<1 %
38	imaginaformacion.com Fuente de Internet	<1 %
39	www.tandfonline.com Fuente de Internet	<1 %
40	cybertesis.uni.edu.pe Fuente de Internet	<1 %
41	repositorio.caen.edu.pe Fuente de Internet	<1 %

42	repositorio.unheval.edu.pe Fuente de Internet	<1 %
43	revistavertice.unison.mx Fuente de Internet	<1 %
44	Submitted to umb Trabajo del estudiante	<1 %
45	worldwidescience.org Fuente de Internet	<1 %
46	Submitted to Universidad Nacional Agraria La Molina Trabajo del estudiante	<1 %
47	www.nobleprog.com.ar Fuente de Internet	<1 %
48	www.produccion.gob.ec Fuente de Internet	<1 %
49	Submitted to Corporación Universitaria Iberoamericana Trabajo del estudiante	<1 %
50	dspace.utpl.edu.ec Fuente de Internet	<1 %
51	repositorio.upse.edu.ec Fuente de Internet	<1 %
52	www.coursehero.com Fuente de Internet	<1 %

Excluir citas

Activo

Excluir coincidencias < 20 words

Excluir bibliografía

Activo

DEDICATORIA

A mi querida esposa Carla, mi amada hija Sofía, mis padres y hermanos por su inmenso amor, apoyo y aliento, su presencia ha sido un gran impulso para fortalecer mi espíritu, motivándome a buscar siempre la superación personal y profesional.

AGRADECIMIENTO

Quiero expresar mi sincera gratitud y aprecio a mi esposa e hija por estar a mi lado y perseverar durante todo el tiempo que duró mi investigación.

Agradezco también a mis padres y hermanos por inculcarme los valores y la determinación necesaria para enfrentar cualquier desafío en la vida.

Además, mi reconocimiento a la Universidad por su excelente programa doctoral, el cual me brindó los conocimientos fundamentales para mi desarrollo profesional.

Por último, quiero extender mi agradecimiento a los doctores, mentores y asesores que contribuyeron de manera significativa y brindaron su valioso apoyo en esta investigación. Su guía fue fundamental para alcanzar los resultados obtenidos.

RECONOCIMIENTO

Quiero expresar mi reconocimiento a la escuela de postgrado de la UAP por su excelencia académica y administrativa, y especialmente a mi asesor Dr. Jorge Luis Bringas Salvador. Su experiencia y profesionalismo fueron fundamentales para proporcionarme la orientación y directrices necesarias para completar mi tesis doctoral en el campo de la Ingeniería de Sistemas.

ÍNDICE

CARÁTULA.....	i
DEDICATORIA	ii
AGRADECIMIENTO	iii
RECONOCIMIENTO	iv
ÍNDICE	v
ÍNDICE DE TABLAS	viii
ÍNDICE DE FIGURAS	ix
RESUMEN	x
ABSTRACT.....	xi
RESUMO.....	xii
INTRODUCCIÓN	xiii
CAPÍTULO I: PLANTEAMIENTO DEL PROBLEMA.....	16
1.1. Descripción de la realidad problemática.....	16
1.2. Delimitación de la investigación.....	19
1.2.1. Delimitación espacial.....	19
1.2.2. Delimitación social	19
1.2.3. Delimitación temporal	20
1.2.4. Delimitación conceptual	20
1.3. Problemas de investigación	20
1.3.1. Problema principal.....	20
1.3.2. Problemas específicos.....	20
1.4. Objetivos de la investigación.....	21
1.4.1. Objetivo general.....	21
1.4.2. Objetivos específicos	21
1.5. Justificación e importancia de la investigación	21
1.6. Importancia de la investigación	22
1.7. Factibilidad de la investigación	23
1.8. Limitaciones del estudio	24
CAPÍTULO II: MARCO FILOSÓFICO	25
2.1. Fundamentación Epistemológica.....	25
2.2. Fundamentación Ontológica.....	27

CAPÍTULO III: MARCO TEÓRICO CONCEPTUAL	29
3.1. Antecedentes del problema	29
3.2. Bases teóricas o científicas	33
3.3. Definición de términos básicos.....	48
CAPÍTULO IV: HIPÓTESIS Y VARIABLES	50
4.1. Hipótesis general.....	50
4.2. Hipótesis específicas.....	50
4.3. Definición conceptual y operacional de las variables.....	50
4.4. Cuadro de operacionalización de variables	52
CAPÍTULO V: METODOLOGÍA DE INVESTIGACIÓN.....	53
5.1. Enfoque de la investigación	53
5.2. Tipo y nivel de investigación.....	53
5.2.1. Tipo de Investigación.....	53
5.2.2. Nivel de Investigación	53
5.3. Métodos y diseño de investigación.....	54
5.3.1. Métodos de Investigación	54
5.3.2. Diseño de la Investigación.....	54
5.4. Población y muestra de la investigación.....	55
5.4.1. Población	55
5.4.2. Muestra	55
5.5. Técnicas e instrumentos de recolección de datos	55
5.5.1. Técnicas	55
5.5.2. Instrumentos.....	56
5.5.3. Validez y confiabilidad.....	56
5.5.4. Procesamiento y análisis de datos.....	57
5.5.5. Ética en la investigación	58
CAPÍTULO VI: RESULTADOS	59
6.1. Análisis descriptivo.....	59
6.2. Análisis inferencial	65
CAPÍTULO VII: DISCUSIÓN DE RESULTADOS	75
7.1. Discusión de resultados	75
7.2. Aporte científico	79
CONCLUSIONES	81

RECOMENDACIONES.....	83
FUENTES DE INFORMACIÓN	85
ARTÍCULO CIENTÍFICO	94
ANEXOS	7
Anexo 1. Matriz de consistencia.....	8
Anexo 2. Instrumentos de recolección de datos	9
Anexo 3. Ficha de validación de instrumento.....	11
Anexo 4. Copia de la data procesada	17
Anexo 5. Consentimiento informado.....	20
Anexo 6. Autorización de la entidad donde se realizó el trabajo de campo	21
Anexo 7: Declaratoria de autenticidad de la tesis.....	22

ÍNDICE DE TABLAS

Tabla 1. Operacionalización de la V.I. - Modelo Deep learning	52
Tabla 2. Operacionalización de la V.D. - Sistema de selección de contratistas	52
Tabla 3. Población de expedientes de contratistas 2020 y 2021	55
Tabla 4. Resultado del juicio de expertos	57
Tabla 5. Frecuencias de D1. Cartera de clientes - i. Relación mercantil con otras empresas.....	60
Tabla 6. Frecuencias de D2. Evaluación crediticia - i. Salud crediticia a nivel de riesgo	61
Tabla 7. Frecuencias de D3. Experiencia real - i. Servicios relacionados.....	62
Tabla 8. Frecuencias del Sistema de selección de contratistas	64
Tabla 9. Resultado de la prueba de normalidad de datos.....	66
Tabla 10. Resumen del modelo para el Sistema de selección de contratistas	67
Tabla 11. ANOVA ^a para el Sistema de selección de contratistas.....	68
Tabla 12. Coeficientes ^a para el Sistema de selección de contratistas	68
Tabla 13. Resumen del modelo para la Cartera de clientes	69
Tabla 14. ANOVA ^a para la Cartera de clientes	69
Tabla 15. Coeficientes ^a para la Cartera de clientes.....	70
Tabla 16. Resumen del modelo para la Evaluación crediticia	71
Tabla 17. ANOVA ^a para la Evaluación crediticia	71
Tabla 18. Coeficientes ^a para la Evaluación crediticia.....	72
Tabla 19. Resumen del modelo para la Experiencia real.....	73
Tabla 20. ANOVA ^a para la Experiencia real.....	73
Tabla 21. Coeficientes ^a para la Experiencia real	74

ÍNDICE DE FIGURAS

Figura 1. Representaciones abstractas en red	33
Figura 2. Neurona convergente con elementos de procesamiento de datos	34
Figura 3. Representación de red neuronal artificial con inputs y output	35
Figura 4. Función tangente hiperbólica	36
Figura 5. Representación de la relación resultante entre la salida y la variable (z).....	37
Figura 6. Representación de la función ReLU.....	37
Figura 7. Arquitectura de la red neuronal	44
Figura 8. Frecuencias en % de D1. Cartera de clientes - i. Relación mercantil con otras empresas.....	60
Figura 9. Frecuencias en % de D2. Evaluación crediticia - i. Salud crediticia a nivel de riesgo.....	61
Figura 10. Frecuencias en % de D3. Experiencia real - i. Servicios relacionados	63
Figura 11. Frecuencias en % del Sistema de selección de contratistas.....	64

RESUMEN

La industria minera forma parte de uno de los sectores productivos de mayor importancia a nivel mundial debido a su papel en la provisión de materias primas para diversos sectores industriales, en este sentido la elección de contratistas para proyectos mineros y servicios puede ser un proceso complejo y costoso para las empresas mineras, sin embargo con el auge de la inteligencia artificial en distintos ámbitos productivos a nivel global, se ha intensificado el uso de modelos Deep Learning para tomar decisiones informadas y objetivas, en ese sentido el propósito del estudio fue determinar la influencia del modelo Deep learning en el sistema de selección de contratistas en el sector minero, Tacna 2023. Metodológicamente fue una investigación de enfoque cuantitativo de tipo aplicada, de nivel descriptivo y explicativo, empleando el método hipotético deductivo, de diseño experimental, longitudinal y preexperimental, con una población y muestra conformada por 213 expedientes de contratistas en el sector minero, siendo la técnica utilizada el análisis documental y el instrumento la ficha de recolección de datos. Sobre el resultado obtenido del estadístico regresión lineal simple, se obtuvo 0.996 y una sig. de 0.000, aceptando la hipótesis alternativa (Ha) y rechazando la hipótesis nula (Ho). Por tanto se concluye que el modelo Deep Learning ha demostrado ser capaz de generar resultados cercanos a las evaluaciones realizadas por el comité de la empresa minera, esta consistencia es muy prometedora, ya que indica que el modelo puede identificar patrones y características importantes en los expedientes de los contratistas, permitiendo hacer recomendaciones acertadas.

Palabras clave: Deep Learning, sistema de selección, contratistas, minera

ABSTRACT

The mining industry is part of one of the most important productive sectors worldwide due to its role in the provision of raw materials for various industrial sectors, in this sense the choice of contractors for mining projects and services can be a complex and expensive process for mining companies, however with the rise of artificial intelligence in different productive areas globally, the use of Deep Learning models has intensified to make informed and objective decisions, in this sense the purpose of the study was to determine the influence of the Deep learning model in the system of selection of contractors in the mining sector, Tacna 2023. Methodologically, it was an investigation of a quantitative approach of an applied type, of a descriptive and explanatory level, using the hypothetical deductive method, of an experimental, longitudinal and pre-experimental design, with a population and sample made up of 213 contractor files in the mining sector, the technique used being documentary analysis and the instrument the data collection form. On the result obtained from the simple linear regression statistic, 0.996 and one sig. of 0.000, accepting the alternative hypothesis (Ha) and rejecting the null hypothesis (Ho). Therefore, it is concluded that the Deep Learning model has shown to be capable of generating results close to the evaluations carried out by the committee of the mining company, this consistency is very promising, since it indicates that the model can identify important patterns and characteristics in the contractors' files, allowing to make correct recommendations.

Keywords: Deep Learning, selection system, contractors, mining

RESUMO

A indústria de mineração faz parte de um dos setores produtivos mais importantes em todo o mundo devido ao seu papel no fornecimento de matérias-primas para vários setores industriais, nesse sentido a escolha de contratados para projetos e serviços de mineração pode ser um processo complexo e caro para as mineradoras, porém com o aumento da inteligência artificial em diferentes áreas produtivas globalmente, o uso de modelos de Deep Learning se intensificou para tomar decisões informadas e objetivas, nesse sentido o objetivo do estudo foi determinar a influência do modelo Deep Learning no sistema de seleção de contratados no setor de mineração, Tacna 2023 Metodologicamente, tratou-se de uma investigação de abordagem quantitativa de tipo aplicado, de nível descritivo e explicativo, utilizando o método dedutivo hipotético, de desenho experimental, longitudinal e pré-experimental, com uma população e amostra constituída por 213 arquivos de empreiteiras do setor de mineração, sendo a técnica utilizada a análise documental e o instrumento a ficha de coleta de dados. No resultado obtido da estatística de regressão linear simples, 0,996 e um sig. de 0,000, aceitando a hipótese alternativa (H_a) e rejeitando a hipótese nula (H_0). Portanto, conclui-se que o modelo Deep Learning tem se mostrado capaz de gerar resultados próximos às avaliações realizadas pelo comitê da mineradora, essa consistência é muito promissora, pois indica que o modelo consegue identificar padrões e características importantes nos arquivos dos contratantes, permitindo fazer recomendações corretas.

Palavras-chave: Deep Learning, sistema de seleção, contratantes, mineração

INTRODUCCIÓN

La industria minera es uno de los sectores más importantes a nivel mundial, ya que proporciona la materia prima necesaria para múltiples sectores industriales. En este contexto, la selección de contratistas para llevar a cabo proyectos mineros y servicios en general puede ser un proceso complejo y costoso para las empresas mineras. Basado en el auge de la inteligencia artificial desde finales de 2022 en diversos procesos productivos a nivel global, la aplicación de modelos de aprendizaje profundo podría ser una solución para mejorar el proceso de selección, permitiendo el análisis de grandes cantidades de datos históricos, identificación de patrones y tomar decisiones informadas y objetivas.

En ese sentido, el propósito de la investigación se enfocó en la necesidad de mejorar el proceso de selección de contratistas en el sector minero de Tacna, Perú, a través del desarrollo de un modelo personalizado de Deep Learning; este modelo permitió evaluar y analizar múltiples criterios y factores de manera eficiente y efectiva, como la experiencia previa, los antecedentes laborales, las habilidades técnicas, el cumplimiento de requisitos legales y normativos, entre otros.

En el primer capítulo, se describió la realidad de la problemática planteada, se establecieron los límites de la investigación y se formularon las preguntas y objetivos que guiaron el estudio, justificándose la importancia de llevar a cabo la investigación, así como su viabilidad y limitaciones.

En el segundo capítulo, como parte del marco filosófico, se utilizaron la epistemología, ontología y axiología como fundamentos esenciales para explorar el conocimiento, el cual se relacionó con el enfoque cuantitativo del estudio.

En el tercer capítulo, se abordaron los estudios previos relacionados con la investigación propuesta, así como las bases teóricas y científicas existentes sobre las variables, luego se definieron los términos básicos y se presentó la operacionalización de las variables en un cuadro.

En el cuarto capítulo, se presentó la hipótesis general y las hipótesis específicas, señalando las variables de estudio con sus definiciones conceptuales y operacionales, respaldadas por autores para una mejor comprensión del estudio.

En el quinto capítulo, se estableció la metodología de investigación, indicando el tipo de investigación, el método y el diseño que se utilizaron como estrategia para recopilar datos de la población identificada, también se utilizaron técnicas e instrumentos validados con un alto nivel de confiabilidad, luego se procesaron y analizaron estadísticamente los datos, aplicando principios éticos en todo el proceso.

En el sexto capítulo, los hallazgos se clasificaron en análisis descriptivos e inferenciales. Estos análisis describieron los resultados para cada indicador de los instrumentos, agrupados según sus dimensiones, luego, se procedió a contrastar las hipótesis para determinar su aceptación o rechazo.

Las conclusiones y recomendaciones finales derivadas de los resultados descriptivos e inferenciales se presentaron en relación con cada objetivo y cómo se logró demostrar el cumplimiento de cada uno, en consonancia con los propósitos de la investigación.

También se presentaron las referencias bibliográficas que respaldaron el proyecto de investigación, utilizando los conocimientos más recientes y relevantes. Además se incluyeron diversos anexos que validaron la propuesta de investigación, como la matriz

de consistencia, la matriz de elaboración de instrumentos, las fichas de validación de instrumentos, los instrumentos de recolección de datos y la declaración de autenticidad.

Por último, se ofrece un artículo de investigación que sigue una estructura bien definida y ordenada, con el propósito de enriquecer el conocimiento existente en el área de Deep Learning en el sistema de selección de contratistas del sector minero peruano. Este artículo proporciona información valiosa y pertinente para guiar la toma de decisiones en la implementación de esta nueva tecnología en IA.

CAPÍTULO I:

PLANTEAMIENTO DEL PROBLEMA

1.1. Descripción de la realidad problemática

En el mundo el sector minero es uno de los más importantes, ya que proporciona materia prima para diversos sectores industriales. Sin embargo, la selección de contratistas para llevar a cabo proyectos mineros puede ser un proceso complejo y costoso para las empresas mineras. En este contexto, el uso de modelos de aprendizaje profundo puede ser una solución para mejorar el proceso de selección de contratistas, ya que permite analizar grandes cantidades de datos históricos y en tiempo real para identificar patrones y tomar decisiones informadas (Maqsoom et al., 2019).

Las cifras sobre el sector minero en diferentes regiones del mundo pueden ser relevantes para contextualizar el problema y justificar la necesidad de una solución eficiente. Por ejemplo, según el informe del Consejo Internacional de Minería y Metales (ICMM) de 2021, la producción minera mundial en 2020 fue de 18,1 billones de toneladas métricas, con un valor de mercado de 802 mil millones de dólares. Además, se estima que la industria minera emplea alrededor de 11 millones de personas en todo el mundo. Estas cifras pueden variar significativamente según la región, por lo que es importante recopilar y analizar datos específicos para cada una de las regiones mencionadas.

Es así como la minería global se encuentra en proceso de expansión y búsqueda de nuevos yacimientos de metales en general, como parte de la cadena productiva, las

empresas exigen que los servicios tercerizados se ejecuten con calidad y dentro de los estándares que cada empresa tiene desarrollados basados en sus objetivos y visión como empresa, según Maqsoom et al. (2019) quienes analizan la selección de contratistas y el proceso de evaluación de ofertas en la industria de la construcción en minería desde la perspectiva del cliente. Los autores argumentan que el proceso actual tiene fallas y que se necesita un enfoque más completo y objetivo. Proponen un enfoque de toma de decisiones de criterios múltiples (MCDM) que permitiría a los clientes seleccionar al contratista que tiene más probabilidades de entregar el proyecto a tiempo, dentro del presupuesto y con los estándares de calidad requeridos.

A nivel Latinoamérica, Rojas, J. & Rojas, M. (2018) quienes analizan la contratación de terceros desde la teoría de juegos, explican que el proceso de selección de contratistas en la industria minera chilena desde la perspectiva de la teoría de juegos. Los autores argumentan que el proceso actual es ineficiente y que se necesita un enfoque más estratégico. Proponen un modelo de teoría de juegos que permitiría a las empresas mineras seleccionar al contratista que tenga más probabilidades de entregar el proyecto al costo más bajo.

A nivel de Perú, Sagástegui Plate, D. E. et al (2021), probaron un modelo de gestión para evaluar empresas contratistas en el sector minero, con el propósito de mejorar los indicadores operativos y la calidad del servicio de los principales proveedores de una empresa minera, ateniendo a la problemática general del sector minero y que es de alto interés sobre la calidad y proceso de contratación de terceros para servicios regulares y altamente especializados. Adicionalmente se enfocan en la calidad en las empresas del sector minero en Perú, determinar la importancia de una cultura de calidad en el sector minero para aprovechar los beneficios del sistema de gestión de calidad y fortalecer a la minera.

A nivel local, Southern es una empresa minera con operaciones en Tacna, Ilo, Moquegua, y se identificó la problemática sobre la necesidad de una gestión eficiente de contratistas para garantizar la calidad de los trabajos y la seguridad de los trabajadores. A medida que la minera experimenta un constante crecimiento, se vuelve fundamental contar con un proceso de selección de contratistas efectivo y confiable. Este proceso de

selección de contratistas en el sector minero es complejo y requiere una evaluación exhaustiva de los antecedentes, habilidades y experiencia de los candidatos.

Sin embargo, los métodos de evaluación actuales a menudo dependen de la intuición humana y pueden ser subjetivos e inconsistentes, esto puede generar riesgos para la calidad de los trabajos y la seguridad de los trabajadores, ya que se podrían contratar empresas o personas que no cuenten con las capacidades necesarias para llevar a cabo las tareas requeridas de manera segura y eficiente. Además, en un entorno minero donde la seguridad y la calidad son prioritarias, es esencial contar con un sistema de selección de contratistas que sea objetivo, confiable y basado en criterios sólidos.

Entre los posibles síntomas de no contar un sistema de selección de contratistas alineado a las necesidades de la empresa, se encuentran: Calidad deficiente de los trabajos realizados por los contratistas al momento, esto puede evidenciarse en trabajos deficientes que requieran retrabajos o que no cumplan con los requisitos especificados. Altos índices de accidentes y lesiones laborales en base al histórico y reportes de seguridad internos de la empresa, por incremento del riesgo de accidentes y lesiones laborales, poniendo en peligro la integridad de los trabajadores y generando costos adicionales para la empresa. Finalmente, otro síntoma se considera el incumplimiento de plazos y presupuestos, por los retrasos en la ejecución de los trabajos y a un aumento en los costos, de servicios u obras tercerizados por partir una de una inadecuada selección de Contratistas a ser invitados al proceso de licitación.

Entre las posibles causas que originan el problema se identifican la falta de criterios claros y estandarizados de evaluación entre las unidades operativas de la empresa (Cuajone, Toquepala e Ilo), dado que esta causa puede llevar a la contratación de contratistas no calificados o no aptos para realizar los trabajos requeridos. La ausencia de procesos estructurados se considera otra causa, dado que, aunque se tenga un procedimiento de contratación y formatos establecidos, los criterios de evaluación para selección de contratistas en diferentes rubros quedan a criterio de cada área operativa de la empresa. Falta de recursos y personal capacitado, ante la rotación de personal y falta de personal capacitado como de herramientas y tecnologías, se convierte en un desafío difícil llevar a cabo una evaluación exhaustiva de los contratistas.

De las consecuencias producto del problema expuesto se tiene el riesgo para la seguridad de los trabajadores al contratar contratistas no calificados o que no siguen las normas de seguridad adecuadas puede poner en peligro la seguridad de los trabajadores, aumentando el riesgo de accidentes y lesiones. Así también incurrir en costos adicionales debido a trabajos de baja calidad se generan costos adicionales para la minera, afectando su rentabilidad y presupuesto. Ello alineado al retraso en los proyectos, lo que afectará la planificación y los plazos establecidos.

En este contexto, la aplicación de tecnologías como el modelo de Deep Learning fue una solución prometedora en el proceso de selección de contratistas en Southern. Considerando que Deep Learning es una rama de la inteligencia artificial que utiliza redes neuronales profundas para el procesamiento y análisis de datos complejos; al implementar un modelo de Deep Learning en el sistema de selección de contratistas, se utilizaron algoritmos avanzados para evaluar de manera objetiva y precisa los antecedentes, habilidades, experiencia de los candidatos y el cumplimiento de requisitos legales y normativos, entre otros, minimizando la influencia de sesgos subjetivos y aumentando la consistencia en la toma de decisiones.

1.2. Delimitación de la investigación

1.2.1. Delimitación espacial

La investigación se llevó a cabo en la empresa minera Southern Perú Copper Corporation Sucursal del Perú, con operaciones en Tacna, Moquegua e Ilo, donde se evaluaron expedientes de contratistas, siendo un margen importante de población y muestra, acorde al nivel de la investigación.

1.2.2. Delimitación social

La investigación se enfocó en los expedientes de contratistas que presentaron las empresas para participar en los procesos de licitación solicitadas por las unidades operativas que tiene la empresa en la región de Tacna, Moquegua e Ilo. Se buscó acceder y emplear los expedientes de contratistas de los años 2020 y 2021.

1.2.3. Delimitación temporal

La investigación se llevó a cabo durante 6 meses, desde febrero 2023 hasta julio 2023, tal como se presentó en el cronograma; ello incluyó la aplicación de los instrumentos en dos momentos del tiempo (corte longitudinal). Esto permitió realizar la comparación entre el pretest y posttest para brindar resultados fehacientes en base a los datos.

1.2.4. Delimitación conceptual

La investigación empleó el sustento epistemológico y ontológico, así como las teorías vigentes sobre el modelo de Deep Learning y el proceso de selección de contratistas en el sector minero de Tacna. Se exploraron los diferentes algoritmos de Deep Learning y se analizaron sus ventajas y desventajas en relación con el sistema de selección de contratistas. Además, se examinaron los diferentes criterios que se utilizan en la selección de contratistas en el sector minero y cómo el modelo de Deep Learning puede mejorar este proceso.

1.3. Problemas de investigación

1.3.1. Problema principal

¿Cuál será la influencia del modelo Deep learning en el sistema de selección de contratistas en el sector minero, Tacna 2023?

1.3.2. Problemas específicos

¿Cuál será la influencia del modelo Deep learning en la Cartera de Clientes de los contratistas en el sector minero, Tacna 2023?

¿Cuál será la influencia del modelo Deep learning en la Evaluación crediticia de los contratistas en el sector minero, Tacna 2023?

¿Cuál será la influencia del modelo Deep learning en la Experiencia real de los contratistas en el sector minero, Tacna 2023?

1.4. Objetivos de la investigación

1.4.1. Objetivo general

Determinar la influencia del modelo Deep learning en el sistema de selección de contratistas en el sector minero, Tacna 2023

1.4.2. Objetivos específicos

Especificar la influencia del modelo Deep learning en la Cartera de Clientes de los contratistas en el sector minero, Tacna 2023

Evaluar la influencia del modelo Deep learning en la Evaluación crediticia de los contratistas en el sector minero, Tacna 2023

Demostrar la influencia del modelo Deep learning en la Experiencia real de los contratistas en el sector minero, Tacna 2023.

1.5. Justificación e importancia de la investigación

Justificación Teórica:

La investigación aportó al conocimiento sobre teoría fundamental y reciente sobre el modelo Deep Learning y el sistema de selección de contratistas, debido a que el contexto minero exigía calidad en el proceso de selección de terceros, y mediante el uso intensivo de TIC's para optimizar los procesos de selección y contratación. Además, la adecuada gestión y selección de contratistas fue crítica para el éxito de la ejecución de los servicios y obras en la empresa minera.

Justificación Práctica:

La implementación de un sistema de selección de contratistas basado en Deep Learning en el sector minero de Tacna, Perú, tuvo una relevancia práctica para la empresa minera de la zona. Permitió a la empresa evaluar la eficacia de este enfoque innovador en su proceso de selección de contratistas, mejorando la calidad de los trabajos y la seguridad de los trabajadores. Los resultados de este estudio proporcionaron información valiosa para la adopción de tecnologías similares por parte de otras empresas mineras en la región, promoviendo una gestión más eficiente y exitosa de los contratistas en la industria minera local. Esto, a su vez, contribuiría a la mejora de los estándares de calidad y

seguridad en el sector y maximizaría la rentabilidad de los proyectos mineros en la zona de Tacna, Perú.

Justificación Metodológica:

El enfoque metodológico de esta tesis se basó en la recopilación y análisis de datos relevantes para el proceso de selección de contratistas en el sector minero. Se utilizaron técnicas de recolección de datos y análisis documental para obtener información detallada sobre los criterios utilizados en la selección de contratistas en la región de Tacna. Además, se implementaron algoritmos de Deep Learning y se realizaron experimentos y pruebas para evaluar la eficacia del sistema propuesto. El enfoque metodológico riguroso garantizó la validez y confiabilidad de los resultados obtenidos y permitió realizar conclusiones sólidas y fundamentadas.

Justificación Social:

El sector minero es una industria importante y estratégica para la economía de Tacna, Perú, y del país en general. Mejorar la eficiencia y rentabilidad de las operaciones mineras no solo beneficiaría a las empresas y a la economía local, sino también a la comunidad en general. Un proceso de selección de contratistas más efectivo y confiable puede garantizar la ejecución exitosa de los proyectos mineros, generando empleo, desarrollo económico y bienestar social en la región. Además, la investigación y el desarrollo de soluciones innovadoras en el sector minero pueden servir como un ejemplo y referencia para otras regiones mineras del país y del mundo, contribuyendo al avance y mejora de la industria a nivel global.

1.6. Importancia de la investigación

La investigación fue importante debido a que el sector minero es uno de los sectores económicos más importantes del Perú y seguirá siendo una fuente de crecimiento económico y empleo en los próximos años. Sin embargo, la selección de contratistas en este sector seguirá siendo un desafío constante, ya que implicará la evaluación de múltiples factores, como la calidad del trabajo, la seguridad laboral, la eficiencia y la capacidad financiera.

Además, la aplicación de la tecnología de Deep Learning en el proceso de selección de contratistas mejoró significativamente la eficiencia y precisión del proceso, lo que permitió una selección más efectiva de contratistas confiables y altamente calificados.

Además, Tacna seguirá siendo una Región importante en el sector minero del Perú, y la implementación de un sistema de selección de contratistas basado en Deep Learning tuvo un impacto significativo en la industria minera local y posiblemente en la economía de la región en general hacia futuro.

Por tanto, la investigación sobre el modelo de Deep Learning y el sistema de selección de contratistas en el sector minero de Tacna en 2023 fue importante para mejorar la eficiencia y precisión en el proceso de selección de contratistas en la industria minera. Esto permitiría la ejecución de servicios u obras por empresas idóneas, reduciendo contingencias de seguridad, calidad o legales durante la ejecución de contratos. En consecuencia, esto puede haber tenido un impacto significativo en la economía y en la industria minera de la región en el futuro.

1.7. Factibilidad de la investigación

A nivel operativo, la ejecución de la investigación fue factible debido a que el investigador principal contó con acceso a la empresa donde se realizó la investigación con operaciones mineras en Tacna, Moquegua e Ilo.

A nivel técnico, se contó con los recursos tecnológicos y conocimientos disponibles para implementar y desarrollar un modelo de aprendizaje profundo en el sistema de selección de contratistas en el sector minero. Esto implicó evaluar la disponibilidad de datos relevantes, herramientas de programación y acceso a la infraestructura necesaria para llevar a cabo la investigación.

A nivel financiero, el autofinanciamiento estuvo asegurado por parte del investigador principal para llevar a cabo la investigación, esto incluyó la financiación necesaria para adquirir equipos, software especializado, contratar personal especializado,

realizar pruebas o realizar cualquier otro gasto asociado con el desarrollo y la implementación del modelo de aprendizaje profundo.

A nivel temporal, se contó con la disponibilidad de tiempo suficiente para llevar a cabo la investigación de manera adecuada, esto implicó considerar el tiempo requerido para recopilar y analizar los datos, desarrollar el modelo de aprendizaje profundo, probarlo, realizar ajustes y presentar los resultados.

1.8. Limitaciones del estudio

De las limitaciones de la investigación, esta se dio a nivel de acceso a la literatura nacional sobre la Deep Learning aplicado al sistema de selección de contratación de contratistas, la cual no era abundante en el sector, lo que dificultó seleccionar antecedentes nacionales adecuados para la investigación y la futura discusión, sin embargo, existía abundante literatura en el extranjero, el cual era pertinente y válido para enriquecer la investigación.

Además, técnicamente existió un número limitado de aplicaciones de Deep Learning en el sector minero y en especial a la selección de contratistas, motivo por el cual fue necesaria abundante información para ser más precisos en los resultados de la evaluación.

Sobre la información, se contó con datos comprendidos entre los años 2020 y 2021, no siendo impedimento para desarrollar el modelo de Deep Learning y brindar los resultados esperados en la investigación propuesta.

CAPÍTULO II:

MARCO FILOSÓFICO

2.1. Fundamentación Epistemológica

La epistemología es una rama de la filosofía que se ocupa del estudio del conocimiento y de los métodos utilizados para adquirirlo. En el caso de la selección de contratistas mineros, la epistemología se refiere a los métodos que se utilizan para adquirir el conocimiento necesario para evaluar las capacidades de los contratistas y decidir cuáles son los más aptos para realizar determinados trabajos en el sector minero.

Modelo Deep Learning

La epistemología del Deep Learning es multidimensional, desde un punto de vista pragmático, este modelo se adhiere a una visión instrumentalista del conocimiento, donde los modelos y algoritmos son herramientas que se utilizan para predecir y controlar los fenómenos del mundo real (Russell & Norvig, 2016). Sin embargo, también tiene un componente constructivista, en el sentido de que el conocimiento se construye a través de la interacción de los algoritmos con los datos.

A partir de lo propuesto por Russel & Norvig, el Deep Learning implica una revisión epistemológica de los conceptos de aprendizaje y conocimiento. Hinton et al. (2006) sostienen que los sistemas de Deep Learning no sólo "aprenden" en el sentido convencional, sino que realmente construyen representaciones internas de los datos con los que interactúan. Estas representaciones, que pueden ser muy complejas y abstractas, constituyen una forma de conocimiento emergente que es intrínseco a la propia red

neuronal. Esta perspectiva se alinea con el enfoque de aprendizaje profundo de Bengio (2009), quien ve el aprendizaje como un proceso de extraer y refinar representaciones internas a partir de datos no estructurados.

El uso del Deep Learning en la investigación también implica una aceptación implícita del paradigma de la ciencia de datos, que combina elementos de las ciencias de la computación, la estadística y los dominios de aplicación específicos para generar conocimiento a partir de grandes conjuntos de datos (Donoho, 2017). En este sentido, la epistemología del Deep Learning se basa en una concepción ampliada del método científico que incluye la experimentación computacional, la exploración de datos y el aprendizaje de máquinas como formas válidas de investigación.

Sistema de selección de contratistas

La epistemología de los sistemas de selección de contratistas se basa en el paradigma de la toma de decisiones en la gestión y la ingeniería. Este paradigma ve la toma de decisiones como un proceso estructurado y racional que se basa en la recopilación y el análisis de datos relevantes (Keeney, 1982). En el caso de la selección de contratistas, estos datos pueden incluir factores como las habilidades y la experiencia de los contratistas, su capacidad para cumplir con los plazos y los presupuestos, su historial de seguridad y su compatibilidad con los objetivos del proyecto.

En ese sentido, Zavadskas et al. (2008) señala que el proceso de selección de contratistas también puede ser altamente contextual y subjetivo, dependiendo de factores como la naturaleza del proyecto, las preferencias de los responsables de la toma de decisiones y las condiciones del mercado. Esto implica que, además de los métodos cuantitativos y objetivos de evaluación, también pueden ser necesarios enfoques cualitativos y subjetivos.

Además, la selección de contratistas también se puede ver desde una perspectiva de gestión de riesgos. Según Aven (2012), la gestión de riesgos implica la identificación, el análisis y la mitigación.

2.2. Fundamentación Ontológica

Modelo Deep Learning

La teoría ontológica de la variable "Modelo de Deep Learning" se enmarca en la teoría de la inteligencia artificial y la ontología de los sistemas de aprendizaje automático. Esta se refiere al estudio de la naturaleza de los modelos de Deep Learning, cómo aprenden de los datos y cómo este aprendizaje puede influir en la toma de decisiones (Goodfellow, Bengio, & Courville, 2016).

Desde una perspectiva ontológica, los modelos de Deep Learning son sistemas autónomos de aprendizaje que tienen una existencia objetiva y que pueden tener un impacto significativo en la toma de decisiones. En este sentido, los modelos de Deep Learning son una realidad objetiva que puede ser medida, evaluada y mejorada a través de técnicas y métodos científicos (Zhang, 2020).

La ontología del modelo de Deep Learning se centra en cómo el modelo interactúa con los datos, y cómo esta interacción se ve afectada por las características ontológicas del modelo. Esto incluye aspectos como la capacidad del modelo para aprender de grandes volúmenes de datos, la adaptabilidad del modelo a diferentes tipos de datos y problemas, y la capacidad del modelo para mejorar y adaptarse con el tiempo (Goodfellow et al., 2016).

Además, la teoría ontológica del modelo de Deep Learning también considera la relación entre el modelo y su entorno socio-técnico. Esto incluye aspectos como las expectativas de los usuarios y especialistas en relación con los modelos de Deep Learning, las normas y regulaciones que rigen el uso de estos modelos, y las implicaciones éticas y sociales de su uso (Floridi & Cowls, 2019).

Sistema de selección de contratistas

La teoría ontológica de la variable "Sistema de Selección de Contratistas" se enmarca dentro de la teoría de los sistemas organizacionales y la ontología de la gestión de proyectos. Esto se refiere al estudio de la naturaleza de cómo las organizaciones seleccionan a sus contratistas y cómo este sistema interactúa con la dinámica de los proyectos y el entorno del negocio (Oyewole, 2018).

Desde la perspectiva ontológica, el sistema de selección de contratistas es una entidad sistémica con existencia objetiva que está conformada por distintas interacciones y relaciones tanto internas (procedimientos de selección, políticas internas, decisiones gerenciales) como externas (normativas legales, condiciones del mercado, comportamiento de los contratistas). Este sistema puede ser medido, evaluado y mejorado a través de técnicas y métodos científicos (Walker, 2007) que concuerda con Oyewole.

La ontología del sistema de selección de contratistas también se centra en cómo los actores humanos y no humanos dentro del sistema interactúan y cómo estas interacciones son afectadas por las características ontológicas del sistema, incluyendo aspectos como la transparencia del proceso de selección, la eficiencia de los criterios de evaluación, y la capacidad del sistema para adaptarse a cambios y demandas (Pryke, 2012).

CAPÍTULO III:

MARCO TEÓRICO CONCEPTUAL

3.1. Antecedentes del problema

3.1.1. Antecedentes Internacionales

Para Taylan et al. (2018) enfocaron su artículo científico “Deep Learning y Big Data en la selección de contratistas para proyectos de construcción mediante herramientas de consenso”, se propuso como objetivo explicar como el Deep Learning y Big Data inciden en la selección de contratistas para proyectos de construcción mediante herramientas de consenso. El enfoque que utilizó fue cuantitativo de diseño experimental y la técnica de evaluación multicriterio (MCDA) para optimizar la selección de contratistas y la asignación de subcontratos, además de la programación lineal entera mixta (MILP). Como resultado concluye que los algoritmos Deep Learning son útiles al momento de seleccionar contratistas por criterios cuantificables sin intervención humana para los proyectos de construcción mediante herramientas de consenso.

Por su lado Kizil & Knights (2020) en su artículo científico "Utilización de la IA y Deep Learning para la selección de proveedores en la industria minera Global" se analiza la aplicación de la inteligencia artificial en la selección de proveedores en la industria minera. Se propone un modelo basado en algoritmos de aprendizaje automático para evaluar y seleccionar proveedores en función de múltiples criterios, incluyendo el desempeño previo y la capacidad de cumplir con los requisitos técnicos y de seguridad.

Por tanto se concluyó que el uso de la inteligencia artificial ha tenido gran influencia en la selección de proveedores mineros.

Es así que Nieto-Morote & Ruz-Vila (2022) en su publicación titulada "Un enfoque difuso basado en Deep Learning para la toma de decisiones multicriterio en la selección de contratistas de construcción", los autores resaltan la importancia fundamental de elegir un contratista adecuado para asegurar el éxito de los proyectos de construcción. El proceso de precalificación de los contratistas presenta desafíos en términos de toma de decisiones debido a la incertidumbre y ambigüedad inherentes a la naturaleza de estos proyectos, así como a la influencia del juicio subjetivo en el proceso de selección. En este estudio, se propone una metodología y un procedimiento sistemático de precalificación basados en la Teoría de Conjuntos Difusos, que ofrece ventajas y diferencias significativas en comparación con otros modelos. Estas ventajas incluyen el uso de un algoritmo para abordar las inconsistencias en las relaciones de preferencia difusas cuando se utilizan juicios de comparación por pares, así como la aplicación de una evaluación lingüística o una evaluación precisa del rendimiento de los contratistas en criterios cualitativos o cuantitativos, respectivamente.

En la investigación de García et al. (2021), indican en su investigación "Un enfoque adaptativo difuso basado en Inteligencia artificial para la selección equilibrada de asignación de riesgos en proyectos de construcción". El objetivo de este estudio es desarrollar un modelo de toma de decisiones híbrido para la selección de contratistas en proyectos de construcción, utilizando una combinación de métodos cuantitativos. La metodología cuantitativa empleada en este estudio se basa en la integración de tres enfoques: el análisis jerárquico (AHP), el método del valor económico (EVM) y el método de la distancia más cercana (NCM). Estos métodos son utilizados para evaluar y clasificar a los contratistas en función de múltiples criterios, buscando lograr una asignación equilibrada de riesgos. De los resultados se concluye que demostraron que el enfoque adaptativo difuso basado en Inteligencia artificial utilizado en este estudio brinda una mejor capacidad para seleccionar y clasificar a los contratistas en proyectos de construcción. El modelo híbrido mostró una mayor eficiencia y precisión en la asignación equilibrada de riesgos, lo que contribuye al éxito de los proyectos y a la toma de decisiones informada en el campo de la construcción.

Según Vardin et al. (2021) en el artículo científico titulado "Modelo integrado de Deep Learning para apoyar la toma de decisiones basado en las técnicas BWM y Fuzzy-VIKOR para la selección de contratistas en proyectos de construcción", El objetivo de su estudio es recomendar el enfoque de la lógica difusa para manejar la incertidumbre y la subjetividad en el proceso de selección. Para lograr su objetivo, se empleó una metodología cuantitativa utilizando las técnicas BWM (Best Worst Method) y Fuzzy-VIKOR. Estos métodos se aplicaron para evaluar y clasificar a los contratistas en función de múltiples criterios. De los resultados se concluye que el modelo integrado de Deep Learning, combinando las técnicas BWM y Fuzzy-VIKOR, brinda un apoyo efectivo para la toma de decisiones en la selección de contratistas para proyectos de construcción. El enfoque de lógica difusa resultó valioso para abordar la incertidumbre y la subjetividad, mejorando el proceso de selección y, en última instancia, contribuyendo a mejorar los resultados de la toma de decisiones.

3.1.2. Antecedentes Nacionales

Para Rodríguez et al. (2020) en su estudio titulado "Un modelo basado en Deep Learning para mejorar el proceso de selección de subcontratistas en proyectos de construcción de carreteras en Perú en 2019", se presenta un enfoque de análisis multicriterio para evaluar y seleccionar subcontratistas en la industria minera peruana. El objetivo de este estudio es utilizar un modelo de toma de decisiones basado en la técnica Analytic Hierarchy Process (AHP) para mejorar el procedimiento de selección de subcontratistas en proyectos de carreteras en Perú en 2019. La metodología cuantitativa empleada en este estudio se basa en el uso de técnicas de Deep Learning. Se consideran diversos criterios, como la experiencia previa, la capacidad técnica, el cumplimiento normativo y los indicadores de seguridad, para evaluar a los subcontratistas y tomar decisiones informadas. Los resultados de este estudio demuestran que el modelo basado en Deep Learning y la aplicación de la técnica AHP mejoran significativamente el proceso de selección de subcontratistas en proyectos de construcción de carreteras en Perú en 2019, logrando una evaluación más precisa y una toma de decisiones más fundamentada, lo que contribuye al éxito y la eficiencia de los proyectos.

También Benavides-Fernandez & Muñoz (2019) presentaron su "Modelo de gestión para evaluación de empresas contratistas del sector minero en el Perú". Esta

investigación propone un modelo de gestión para evaluar a las empresas contratistas del sector minero en el Perú. El modelo busca mejorar los indicadores operativos y la calidad del servicio de los principales proveedores de las empresas mineras. Como conclusión se identifica la falta de un modelo de gestión estándar y se propone una solución escalable.

Es así que Zambrano & Vidal (2018) detallaron en su investigación "Evaluación de proveedores en la industria minera peruana: Un enfoque de multicriterio utilizando tecnología de datos" aborda la evaluación de proveedores en la industria minera peruana utilizando un enfoque de multicriterio. Se consideran criterios como la calidad, el costo, la capacidad técnica y el cumplimiento normativo. Se propone un modelo de evaluación basado en la teoría de la Utilidad Multicriterio Aditiva (MAUT) para apoyar la toma de decisiones en la selección de proveedores.

Por otro lado, Carreño & Sanchez (2019) en su artículo "Evaluación de contratistas en la industria minera peruana: un enfoque basado en el índice de capacidad financiera e inteligencia artificial" presentan un enfoque de evaluación de contratistas en la industria minera peruana basado en el índice de capacidad financiera. Se utiliza un modelo que considera indicadores financieros clave para evaluar la solidez económica de los contratistas y su capacidad para cumplir con los requerimientos de los proyectos mineros. El modelo propuesto ayuda en la selección de contratistas confiables y financieramente sólidos.

Finalmente, Casanova et al. (2020) en el artículo "Procedimiento de selección de subcontratistas en proyectos de carreteras en el Perú mediante el análisis multicriterio y enfoque de inteligencia artificial" presenta un enfoque de análisis multicriterio para la evaluación y selección de contratistas en la industria minera peruana. Se consideran diversos criterios, como la experiencia previa, la capacidad técnica, el cumplimiento normativo y los indicadores de seguridad. Se utiliza un modelo de toma de decisiones basado en la técnica Analytic Hierarchy Process (AHP) para ayudar en la selección de contratistas

3.2. Bases teóricas o científicas

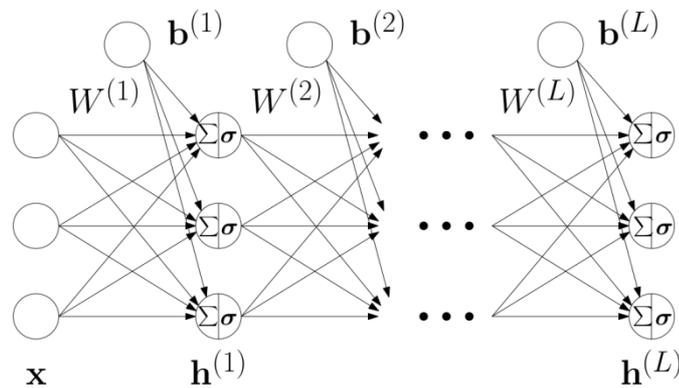
3.2.1. Variable Modelo Deep Learning

Modelo Deep Learning, según Goodfellow et al. (2016), es un conjunto de técnicas de Machine Learning que utilizan redes neuronales y se caracteriza por utilizar múltiples capas de procesamiento no lineales para modelar abstracciones de alto nivel en diferentes tipos de datos como fotos, videos y audio, esta técnica se ha utilizado en diversos campos, como la visión por computadora y el procesamiento del lenguaje natural.

Por su lado Bengio (2009) concuerda que las redes neuronales profundas son capaces de aprender de manera automática características y representaciones de los datos que se utilizan para la tarea de interés, sin necesidad de diseñar manualmente estas características, además la arquitectura de las redes neuronales profundas se compone de múltiples capas ocultas que procesan los datos y aprenden representaciones cada vez más abstractas a medida que se avanza en la red.

Figura 1

Representaciones abstractas en red



El proceso de extracción de características en el Deep Learning se lleva a cabo de manera automática gracias a la utilización de múltiples capas de procesamiento no lineal (Bengio, 2009). A diferencia de los algoritmos de Machine Learning tradicionales, en los que la extracción de características debe ser realizada manualmente, el Deep Learning es capaz de aprender las características relevantes de los datos de manera autónoma (Goodfellow et al., 2016). Además, este proceso de extracción de características emula el

comportamiento de la corteza visual, es decir, extrayendo características del más bajo al más alto nivel (Bengio, 2009). De esta manera, se pueden obtener abstracciones de alto nivel de los datos de entrada, lo que permite una mejor interpretación y utilización de la información contenida en los mismos.

Dimensión de clasificación por redes neuronales artificiales multiclase

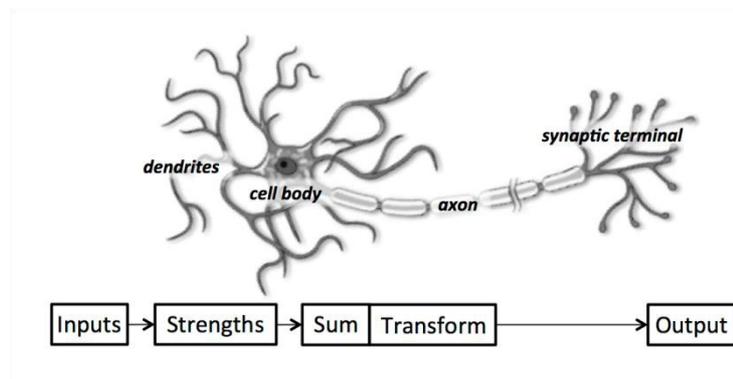
Según Goodfellow et al. (2016), esta dimensión se compone por diferentes elementos como las redes neuronales artificiales y las funciones de activación los cuales se describen a continuación:

Red neuronal artificial

Para Goodfellow et al. (2016), una red neuronal artificial (RNA) es un modelo matemático que se compone de un conjunto de neuronas o nodos interconectados por conexiones, con el objetivo de procesar señales de entrada y emitir señales de salida. Explican que el modelo matemático se inspira en el proceso de aprendizaje que ocurre en el sistema nervioso, y se caracteriza por aprender a través de la experiencia y extraer conocimiento genérico a partir de un conjunto de datos. Las RNAs son una técnica de modelado matemático que ha demostrado ser útil en diversas aplicaciones de Machine Learning, como en el reconocimiento de imágenes, el procesamiento del lenguaje natural y la predicción de valores.

Figura 2

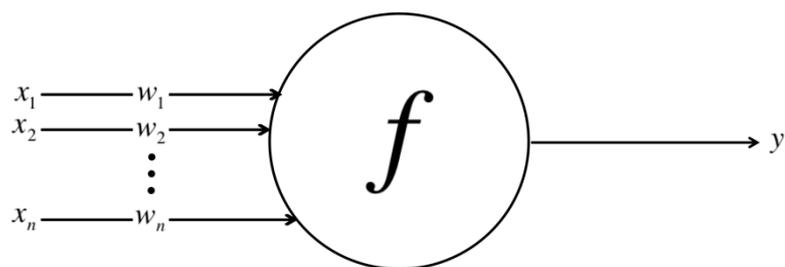
Neurona convergente con elementos de procesamiento de datos



La función de activación de la neurona artificial es similar al potencial de acción de la célula biológica, es decir, si la activación resultante de la suma ponderada de entradas supera un cierto umbral, entonces se producirá una señal de salida, esta señal es enviada a las neuronas conectadas a través de conexiones sinápticas, además esta operación de propagación de la señal a través de múltiples capas de neuronas interconectadas es lo que permite a las redes neuronales artificiales aprender patrones complejos y realizar tareas como clasificación, regresión y generación de texto, entre otras (Goodfellow, Bengio, & Courville, 2016)

Figura 3

Representación de red neuronal artificial con inputs y output



$$z = \sum x_i w_i$$

$$y = f(z)$$

Nota. (f) es la función de activación. Esta salida puede ser transmitida a otra neurona.

Funciones de activación

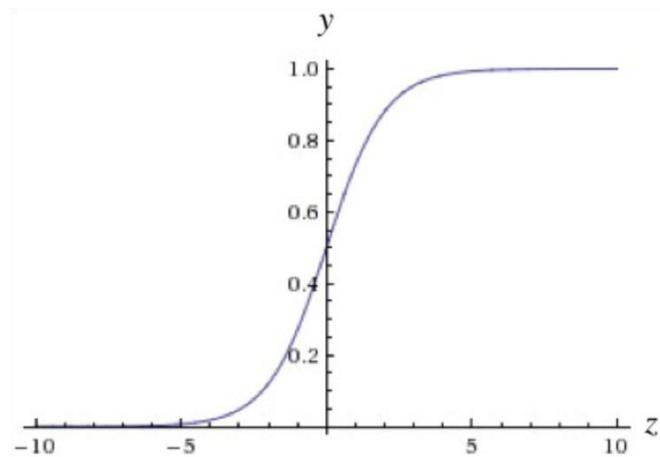
Existen tres tipos de funciones de activación ampliamente utilizadas en redes neuronales, las cuales son fundamentales para introducir la no linealidad en sus cálculos (Goodfellow et al., 2016). Una de ellas es la función sigmoide, que se utiliza en redes neuronales con una sola capa oculta. La función sigmoide tiene

una forma curva de "S" y transforma cualquier entrada en un rango de 0 a 1, lo que la hace útil para la clasificación binaria y la probabilidad estimada. Sin embargo, puede tener problemas de gradiente en redes neuronales profundas, lo que lleva a una disminución en la velocidad de convergencia (Goodfellow, Bengio, & Courville, 2016)

Figura 4

Función tangente hiperbólica

$$f(z) = \frac{1}{1 + e^{-z}}$$



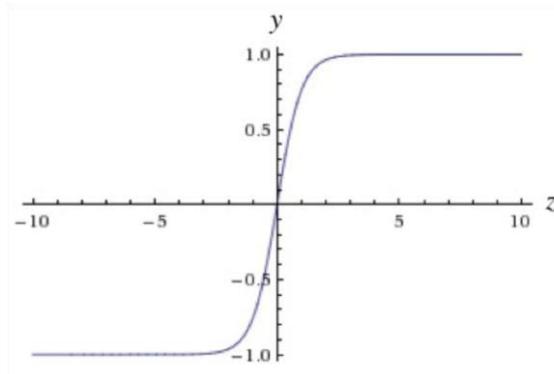
la función tangente hiperbólica (\tanh) es similar a la función sigmoide, pero transforma la entrada en un rango de -1 a 1, lo que la hace útil para la clasificación binaria con valores negativos.

$$f(z) = \tanh(z)$$

Esta relación resultante entre la salida y la variable z se representa en la figura.

Figura 5

Representación de la relación resultante entre la salida y la variable (z)



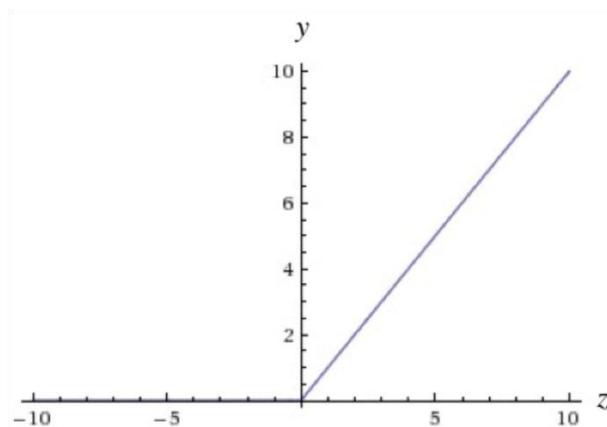
Otro tipo de función de activación es la función ReLU, que es la más utilizada en redes neuronales profundas. ReLU transforma cualquier entrada negativa en 0 y deja la entrada positiva sin cambios, lo que aumenta significativamente la velocidad de entrenamiento de la red neuronal (Goodfellow et al., 2016).

$$f(z) = \max(0, z)$$

El resultado se muestra en la figura.

Figura 6

Representación de la función ReLU



Dimensión de clasificación por algoritmos de recomendación

En el ámbito de los sistemas de recomendación, Goodfellow et al. (2016) establece dos criterios principales que los distinguen: por un lado, están aquellos que generan recomendaciones personalizadas como salida; y por otro, aquellos que guían al usuario de manera personalizada para sus intereses dentro de un dominio con un gran número de ítems posibles. En consecuencia, los sistemas de recomendación pueden ser vistos como un tipo de filtro de información que busca mostrar al usuario ítems relevantes o de interés para él.

Sistemas basados en el contenido

Los sistemas de recomendación basados en el contenido son aquellos que toman en cuenta las características o atributos de los ítems que el usuario ha evaluado positivamente en el pasado. Este enfoque utiliza técnicas de análisis de contenido para extraer información relevante sobre los ítems, como palabras clave, etiquetas, género, actores, entre otros, y luego busca recomendaciones similares en función de estas características.

Este enfoque es especialmente útil cuando el conjunto de datos es escaso o cuando los usuarios tienen preferencias únicas y no se pueden encontrar suficientes usuarios similares para realizar recomendaciones precisas. Sin embargo, estos sistemas también tienen limitaciones, como la incapacidad de proporcionar recomendaciones sorprendentes o introducir nuevos ítems que el usuario no haya visto antes (Goodfellow et al., 2016)

Inferencia sobre el conocimiento

En los sistemas de recomendación, la obtención de datos es solo el primer paso. Es necesario procesar y analizar estos datos para poder hacer recomendaciones útiles para los usuarios. Según Goodfellow et al. (2016), los algoritmos de inferencia de conocimiento son fundamentales para el éxito de los sistemas de recomendación.

Estos algoritmos procesan los datos y crean un modelo de usuario que refleja los intereses y preferencias del usuario. Dado este modelo de usuario, la función de inferencia puede predecir si un ítem nuevo será del agrado del usuario. Entre las diferentes formas de inferir en el conocimiento almacenado en el sistema se encuentran el filtrado colaborativo, el filtrado basado en contenido y el filtrado híbrido que combina ambas técnicas (Adomavicius y Tuzhilin, 2005). Cada técnica tiene sus propias ventajas y desventajas, y la elección de la técnica adecuada depende de las características específicas del problema y de los datos disponibles.

Personalización del usuario

La personalización del usuario en los sistemas de recomendación implica que el usuario aporta información sobre sus preferencias de gustos a través de una interfaz proporcionada por el sistema. Una vez que se han recopilado estas preferencias, el sistema busca los elementos que coinciden con los parámetros indicados por el usuario. Este método requiere que el usuario se involucre activamente al completar un formulario o cuestionario para que el sistema pueda realizar recomendaciones personalizadas (Goodfellow et al., 2016).

Sin embargo, este método presenta algunas limitaciones. En primer lugar, los usuarios pueden tener dificultades para proporcionar información precisa sobre sus preferencias, lo que puede llevar a recomendaciones imprecisas. En segundo lugar, no se proporciona ninguna forma para determinar el orden en que se presentan los resultados obtenidos por el sistema, lo que puede resultar en una sobrecarga de información para el usuario. Por lo tanto, es importante que los sistemas de recomendación también consideren técnicas para ordenar y presentar los resultados de manera efectiva y relevante para el usuario (Herlocker et al., 2004).

Basadas en reglas (*Rule based*): Los sistemas de recomendación basados en reglas utilizan una serie de reglas predefinidas para generar recomendaciones para los usuarios. Estas reglas se basan en el historial de compras o evaluaciones del usuario, y el sistema utiliza esa información para recomendar nuevos

productos o servicios. Por ejemplo, si un usuario ha comprado los capítulos dos y tres de una serie de televisión, el sistema puede recomendar automáticamente el capítulo cuatro de esa serie, basándose en la regla predefinida de que los usuarios que compraron los capítulos dos y tres también compraron el capítulo cuatro. Sin embargo, este método puede tener limitaciones si el historial de compras del usuario es limitado, ya que el sistema no tendrá suficiente información para generar recomendaciones precisas y personalizadas. (Goodfellow et al., 2016).

Reglas de asociación (*Associative rules*): Las reglas de asociación son utilizadas en los sistemas de recomendación para descubrir relaciones entre los ítems, lo que posteriormente puede ser utilizado para hacer recomendaciones personalizadas. Para establecer estas relaciones, se comparan los comportamientos pasados de los usuarios con respecto a los ítems. Un ejemplo de esto podría ser la compra de cereales junto con la compra de leche en una tienda en línea. Amazon es una empresa que ha utilizado este método en su sistema de recomendación. (Liden, G., Smith, B. & York, J., 2003)

Árboles de decisión (*Decisiontree*): Los sistemas de recomendación basados en árboles de decisión utilizan una estructura en forma de árbol para organizar y distribuir la información (Goodfellow et al., 2016). Esta estructura consta de nodos que contienen atributos, arcos que contienen los posibles valores del nodo padre y hojas que clasifican el ejemplo. Para elaborar recomendaciones, el algoritmo comienza en el nodo padre y evalúa sus atributos para seleccionar un arco. Este proceso se repite iterativamente hasta alcanzar una hoja que proporciona una recomendación para el usuario. Este método es recomendable en casos donde el número de atributos es reducido (M.J. Pazzani y D. Billsus, 2007). Un ejemplo de algoritmo de árbol de decisión es el ID3. En un ejemplo presentado por (J.W. Kim, B.H. Lee, M.J. Shaw, H.L. Chang, y M. Nelson, 2007), se muestra cómo un sistema de recomendación basado en árboles de decisión es utilizado en la práctica.

Método del vecino más cercano: El método del vecino más cercano es una técnica utilizada en sistemas de recomendación basados en el contenido para

inferir las preferencias de los usuarios sobre ítems no valorados. Para ello, se compara el ítem sin valorar con los ítems ya valorados por el usuario mediante una función de similitud, y se obtienen los vecinos más cercanos. A partir de las etiquetas de los vecinos más cercanos, se puede inferir la(s) etiqueta(s) para el nuevo ítem. Este método se puede aplicar en diferentes estructuras de datos, y las funciones más comunes son la distancia euclidiana y el modelo de espacio vectorial (Goodfellow et al., 2016). El método del vecino más cercano es una técnica simple pero efectiva para sistemas de recomendación basados en el contenido, y su eficacia depende de la calidad de las funciones de similitud utilizadas y de la cantidad de datos disponibles para el usuario.

Feedback relevante: El feedback relevante es un método que busca mejorar la calidad de las recomendaciones al obtener información directa del usuario sobre la utilidad de los ítems recomendados. Este método es comúnmente utilizado en sistemas (Rocchio, 1971) de recomendación de contenido y en sitios web de soporte técnico. En este proceso, el sistema solicita al usuario una evaluación de los ítems recomendados en base a su relevancia para la búsqueda realizada. La retroalimentación del usuario se utiliza para mejorar la precisión de las recomendaciones futuras. Uno de los algoritmos más utilizados para implementar este método es el algoritmo de "Rocchio", que utiliza la retroalimentación del usuario para ajustar el perfil del usuario y, en consecuencia, mejorar la relevancia de las recomendaciones (Goodfellow et al., 2016).

Clustering: El método de "clustering" es una alternativa más eficiente para obtener recomendaciones para un usuario en particular. En lugar de realizar un cálculo para cada usuario individualmente, se agrupan a los usuarios en categorías según sus comportamientos pasados. Cada grupo o "cluster" tiene preferencias típicas que se pueden utilizar para ofrecer recomendaciones a los usuarios dentro de cada grupo. El enfoque de clustering permite trabajar con datos agregados, lo que lo hace más eficiente que otros métodos. Aunque las recomendaciones a nivel grupal son menos precisas que en el filtrado colaborativo a nivel individual, el "clustering" puede ser una técnica útil para reducir las búsquedas en el filtrado colaborativo.

Dimensión de clasificación por algoritmo transformer.

Para Goodfellow et al. (2016) existen diversos algoritmos que se emplean en el proceso de clasificación siendo los siguientes.

Algoritmo de entrenamiento Backpropagation, Según expone Goodfellow et al. (2016) backpropagation es un algoritmo de entrenamiento supervisado que se utiliza en redes neuronales artificiales para minimizar el error de predicción entre la salida deseada y la salida real de la red. El proceso consiste en propagar el error desde la capa de salida hacia las capas ocultas, y luego ajustar los pesos sinápticos de las neuronas en esas capas ocultas para reducir el error. El objetivo del aprendizaje de la red es minimizar la función de error, que se define como la suma de los errores cometidos por la red en cada patrón de entrenamiento. En otras palabras, el algoritmo de backpropagation trata de encontrar los pesos de las conexiones sinápticas que minimizan la función de error global de la red (Rumelhart et al., 1986). La fórmula del algoritmo de entrenamiento Backpropagation se puede desglosar en varios pasos:

- Propagación hacia adelante: se alimenta la red neuronal con un conjunto de datos de entrenamiento, y se calcula la salida de cada neurona en la red, comenzando por la capa de entrada y avanzando hacia la capa de salida.
- Cálculo del error: se compara la salida de la red con la salida deseada para cada ejemplo de entrenamiento, y se calcula el error cometido. El error se puede calcular utilizando diversas métricas, siendo una de las más comunes la suma de los errores al cuadrado.
- Propagación hacia atrás: se propaga el error desde la capa de salida hacia las capas ocultas de la red. Para cada neurona, se calcula el error cometido y se distribuye entre las conexiones entrantes de la neurona, en proporción a la fuerza de cada conexión.
- Actualización de los pesos: se actualizan los pesos de cada conexión de la red, en función del error propagado hacia atrás y de una tasa de aprendizaje predeterminada. La tasa de aprendizaje controla la magnitud de los cambios realizados en los pesos en cada iteración del algoritmo.

- Repetición: se repiten los pasos anteriores para cada ejemplo de entrenamiento, y se ajustan los pesos de la red para reducir el error cometido en el conjunto de entrenamiento.

El objetivo del algoritmo de entrenamiento Backpropagation es minimizar el error cometido por la red neuronal en la tarea de clasificación o regresión para la que ha sido entrenada. Al ajustar los pesos de las conexiones de la red, se busca que la red aprenda a reconocer patrones en los datos de entrada y a producir salidas precisas y relevantes en función de esos patrones.

Minimización del error:

$$\min E = 1/2N \sum_{n=1} (t^n - y^n)^2$$

Donde:

N = número de patrones

t^n = salida deseada para el patrón n

y^n = salida real de la red para el patrón n

Cálculo del error:

$$E(n) = 1/2 \sum_{j=1} (t^j - y^j)^2$$

Donde:

j = índice de la neurona de salida

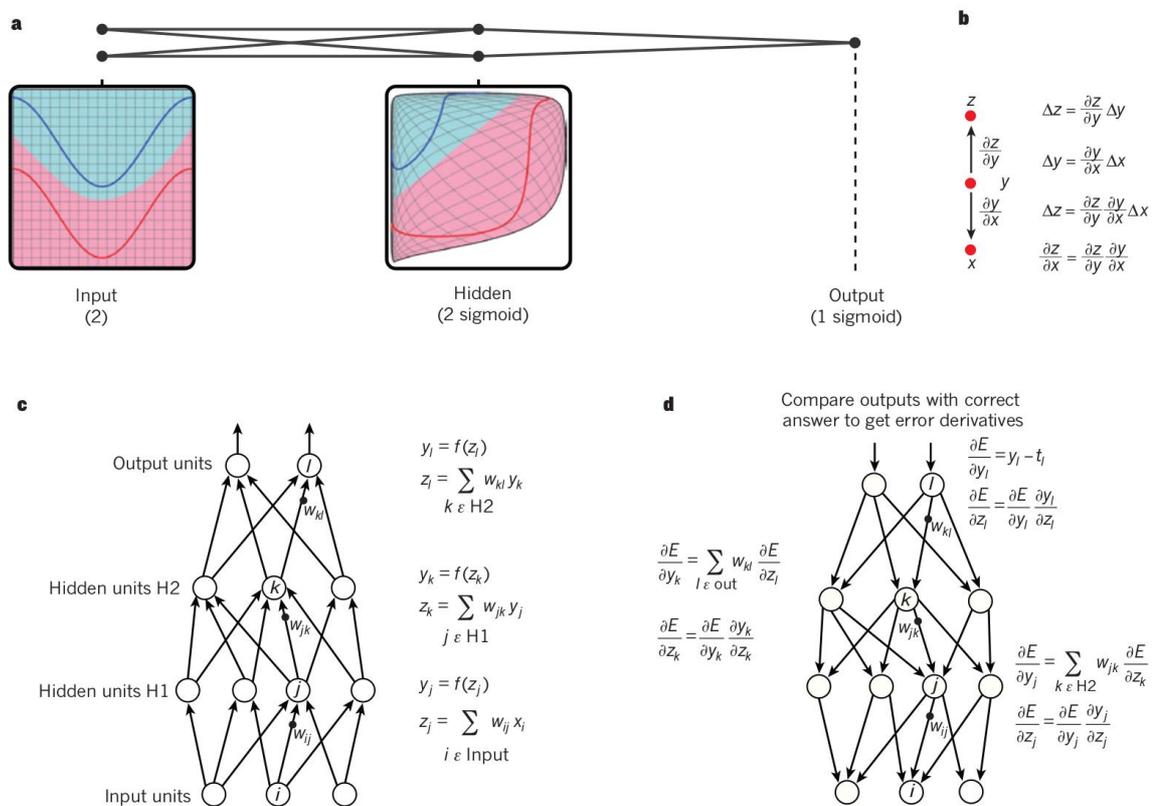
t^j = salida deseada para la neurona j

y^j = salida real de la red para la neurona j

Además, algunos estudios han demostrado que en ciertos casos, las redes neuronales profundas pueden superar a las redes neuronales menos profundas en términos de precisión y eficacia en el aprendizaje de tareas complejas (Hinton et al., 2012). Por lo tanto, la elección de la arquitectura de la red neuronal depende del problema específico que se esté tratando, y es importante evaluar cuidadosamente los beneficios y limitaciones de cada enfoque.

Figura 7

Arquitectura de la red neuronal



Por tanto el algoritmo de propagación hacia atrás es una herramienta útil para entrenar redes neuronales artificiales, pero es importante tener en cuenta sus limitaciones, especialmente en redes neuronales profundas. La elección de la arquitectura adecuada de la red neuronal depende del problema específico y puede requerir la implementación de técnicas adicionales para abordar los problemas de dilución del error.

3.2.2. Variable sistema de selección contratistas

Según Oyewole (2018) define que el sistema de selección de contratistas en el contexto del sector minero, gas y petróleo involucra evaluar y analizar múltiples criterios y factores para determinar la idoneidad de los contratistas para llevar a cabo proyectos y servicios en la industria minera. En esta variable, se identifican tres dimensiones clave: la cartera de clientes de los contratistas, la evaluación crediticia de las empresas y la experiencia real de trabajos previos. La precalificación es un proceso de preselección para identificar a los licitadores adecuados a los que se invitará a participar en la contratación de bienes y servicios. bienes y servicios.

Los programas de certificación de precalificación están diseñados para establecer un grupo bien cualificado y experimentado de contratistas y subcontratistas que actuarán en los contratos y experimentados de contratistas y subcontratistas que actuarán en los contratos. Se trata de evaluar las capacidades clave de los solicitantes y ayudarles a conseguir capacidades adicionales para para que puedan optar a contratos. La precalificación no garantiza no garantiza la inclusión en una lista maestra de licitaciones, pero es un paso esencial en el proceso general de obtención de un contrato para suministrar bienes o servicios a una empresa. un contrato para suministrar bienes o servicios a la industria de origen, así como una oportunidad para que los de acceder a otros mercados similares.

Para evaluar el impacto percibido de diversos criterios de selección de contratistas en el éxito de los proyectos, Russell et al. (1992) explican que existen tres criterios mejor valorados como la estabilidad financiera, la experiencia y los resultados anteriores. Hatush y Skitmore (1997) también consideran criterios de selección como el éxito del proyecto, en términos de tiempo, coste y calidad. Los criterios que se percibían como más influyentes en los tres factores de éxito eran los fracasos anteriores, la situación financiera, la estabilidad financiera, la calificación crediticia, la experiencia, la capacidad, el personal directivo y los conocimientos de gestión, mientras que se consideraba que los criterios de seguridad y la antigüedad en el negocio eran los que menos efecto tenían.

También Singh y Tiong (2006) definen los criterios relacionados con la experiencia, los resultados anteriores y la estabilidad financiera de los contratistas centrado en el impacto percibido y no confirmando un vínculo real entre estos criterios y el éxito de los

proyectos de construcción. También Alzhrani y Emsley (2013) explican que los proyectos desde un punto de vista posterior a la construcción muestran criterios como el historial de facturación, la política de calidad y la adecuación de los recursos de mano de obra e instalaciones, la eliminación de residuos, el tamaño de los proyectos realizados en el pasado y la imagen de la empresa.

En base a Oyewole (2018) se deben emplear las siguientes dimensiones para evaluar el sistema de selección de contratistas.

Dimensión Cartera de clientes

Para Oyewole B. (2018) explica que la cartera de clientes de los contratistas se refiere a la lista de empresas o proyectos para los cuales han trabajado anteriormente. Esto proporciona una indicación de la experiencia y la reputación de los contratistas en la industria minera. Una cartera de clientes sólida puede indicar la confianza y la satisfacción de otras empresas en el desempeño de los contratistas.

Dimensión Evaluación crediticia de las empresas

Detallando el aspecto de evaluación crediticia de las empresas, Oyewole B. (2018) indica que la evaluación crediticia de las empresas contratistas se centra en analizar la solidez financiera y la capacidad de cumplir con las obligaciones financieras. Esto implica evaluar factores como el estado financiero, la capacidad de pago y las referencias crediticias. El solicitante de la precalificación como proveedor de servicios deberá presentar información financiera que permita a las autoridades y a las empresas petroleras, mineras y de gas evaluar su capacidad e información financiera que permita a las autoridades y a las empresas petroleras, mineras y de gas evaluar su capacidad financiera para ejecutar los contratos. capacidad financiera para ejecutar los contratos. Las empresas pueden facilitar sus informes anuales publicados y presentados ante una autoridad reguladora y complementar dichos informes con cualquier información que no figure en los mismos.

- Los estados financieros consolidados auditados del Solicitante correspondientes a los tres (3) últimos años, incluidos el balance, la cuenta de pérdidas y ganancias, el estado de cambios en los de cambios en el patrimonio neto, el estado de flujos de efectivo,

las notas a las cuentas y, cuando así lo exija la legislación local o los principios contables aplicables, el informe de gestión.

- El informe o informes del auditor o auditores que hagan referencia a los mencionados estados financieros de del prestador de servicios, firmado por un contable público independiente y elaborado de conformidad con las normas de auditoría aplicables.
- Calificación crediticia o perfil de endeudamiento actual e histórico (tres (3) años anteriores) del proveedor de servicios (o de su empresa matriz), por una oficina de crédito, si existe.
- Descripción de las principales líneas de crédito, contratos de crédito, títulos de deuda negociados públicamente, cuentas de orden, etc. del proveedor de servicios.
- Detalles de cualquier plan a medio plazo y/o pasivos contingentes importantes, si se pudiera Si cabe esperar razonablemente que afecten material y negativamente a la situación financiera del proveedor de servicios.
- Una declaración en la que se describan los cambios importantes que se hayan producido en cualquiera de los datos anteriores, desde la fecha en que se preparó dicha información.
- Cualquier información adicional en apoyo de la capacidad financiera del proveedor de servicios que permita a las autoridades y a las empresas petroleras, mineras y de gas tomar una decisión justa sobre la capacidad para ejecutar el contrato.

Dimensión Experiencia real de trabajos

Un solicitante podrá optar al proceso de precalificación si es capaz de presentar pruebas de que dispone de procedimientos operativos adecuados en materia de calidad, salud, seguridad, medio ambiente y desarrollo comunitario, Medio ambiente y desarrollo comunitario. El solicitante debe demostrar, a satisfacción razonable las autoridades reguladoras y las empresas petroleras, mineras y de gas, su capacidad para cumplir todas las normas internacionales aplicables en estos ámbitos de acuerdo a Oyewole B. (2018) Todas las normas internacionales aplicables en estos ámbitos. En concreto, se podrá exigir al solicitante que presentar documentos que incluyan:

- Declaraciones de política de calidad, salud, seguridad y medio ambiente (QHSEC).
- Pruebas de la existencia y aplicación de sistemas de gestión de la calidad, la salud, la seguridad y el medio ambiente.

- Pruebas de las relaciones establecidas con la comunidad y de la política y los programas de desarrollo.
- Certificaciones QHSEC de acuerdo con las mejores prácticas internacionales del sector (por ejemplo, certificación ISO 9001, ISO 14001 y/o OHSAS 18001), con copias de los certificados aprobados por las autoridades oficiales competentes por las autoridades oficiales otorgantes.
- Una copia de los sistemas de gestión de la calidad, la salud, la seguridad y el medio ambiente o su equivalente.
- Copia de los informes o iniciativas de Responsabilidad Social Corporativa de los últimos tres (3) años.
- Detalles sobre la experiencia con respecto a los contratos pertinentes realizados en las categorías solicitadas en los últimos tres (3) años.
- Registro QHSEC de sucesos importantes de los tres (3) años anteriores, incluidos derrames de petróleo, accidentes mortales y lesiones en el emplazamiento, incendios graves y accidentes graves accidentes mortales y lesiones, incendios y explosiones graves, averías mecánicas/estructurales, emisiones y residuos, y principales medidas de reparación, emisiones y residuos, y principales medidas correctoras y estrategias de prevención.
- Lista de expertos técnicos con cualificaciones y experiencia pertinentes para ejecutar el contrato en las categorías solicitadas.
- Lista de equipos y materiales necesarios para la ejecución del contrato en las categorías pertinentes del proyecto.
- Cualquier otra información técnica que pueda permitir a las autoridades reguladoras y a las empresas petroleras, mineras y de gas tomar una decisión fundamentada sobre los aspectos técnicos del proyecto.

3.3. Definición de términos básicos

Eficiencia: se refiere a que el usuario siente que el software está permitiendo que las taks sean realizados de forma rápida, eficaz y económica o, en el extremo opuesto, que el software obstaculiza el rendimiento según (Arh & Blažič, 2008).

Control: grado en el que el usuario siente que él, y no el producto, está marcando el ritmo del uso del software según (Weheba et al., 2017).

Utilidad: se refiere a las percepciones del usuario que utiliza el software y se considera útil en la resolución de problemas operacionales según (Hayat et al., 2015).

Sistema: es la combinación de hardware (HW) y/o software (SW) y/o servicios y/o personas que interactúan para lograr objetivos específicos según la (ISO, 2010)

Servicio: son los medios de entregar valor para el cliente, facilitando resultados que el cliente desea lograr. Los servicios pueden incluir interacciones entre el sistema humano (por ejemplo, acceder a un procesador de textos a través de la web) como interacciones entre humanos (por ejemplo, un ciudadano que interactúa con un empleado en el mostrador de la oficina de correos). El "cliente" es un usuario y no necesariamente tiene una relación financiera. Así lo refiere la (ISO/IEC, 2012)

Usuario: es quien interactúa con un determinado sistema, producto o incluso un servicio como señala la (ISO, 2011).

Extracción de características: La extracción de características es el proceso de transformar datos crudos en un conjunto de características significativas que puedan ser utilizadas en la etapa de entrenamiento de un modelo de aprendizaje automático según (Goodfellow, Bengio, & Courville, 2016)

Termino de referencia: Es un documento que está elaborado por una entidad y que detalla las condiciones, características y métodos que se deben seguir para realizar un servicio o trabajo dentro de un plazo establecido y con hitos de ejecución específicos (Nuñez Salas & Talavera Cano, 2021)

Contrato: El contrato es un acuerdo entre dos o más personas que establece derechos y deberes para ambas partes que se rige por el principio de autonomía de la voluntad, que permite la contratación sobre cualquier materia no prohibida. (Project Managment Institute, 2021).

Contratista: Se refiere a un individuo, compañía o persona jurídica que tiene un acuerdo formal para realizar un trabajo o prestar un servicio específico a través de un contrato de cadena de suministro o de servicios temporales (Anglo American, 2023).

CAPÍTULO IV:

HIPÓTESIS Y VARIABLES

4.1. Hipótesis general

Existe influencia del modelo Deep learning en el sistema de selección de contratistas en el sector minero, Tacna 2023.

4.2. Hipótesis específicas

Existe influencia del modelo Deep learning en la Cartera de Clientes de los contratistas en el sector minero, Tacna 2023.

Existe influencia del modelo Deep learning en la Evaluación crediticia de los contratistas en el sector minero, Tacna 2023.

Existe influencia del modelo Deep learning en la Experiencia real de los contratistas en el sector minero, Tacna 2023.

4.3. Definición conceptual y operacional de las variables

Definición conceptual: Modelo Deep learning

Para Goodfellow et al. (2016), un modelo de Deep Learning se compone de capas conectadas entre sí que procesan la información de entrada con el objetivo de generar una salida. Estas capas están diseñadas para extraer características cada vez más abstractas y complejas de los datos a medida que la red neuronal se adentra en ellas. Los modelos de

Deep Learning tienen la capacidad de aprender de forma autónoma a partir de los datos, lo que los hace ideales para tareas como clasificación, reconocimiento de patrones, procesamiento del lenguaje natural, análisis de imágenes y mecanismos de atención.

Definición operacional: Modelo Deep Learning

Según Goodfellow et al. (2016), se debe realizar el proceso de entrenamiento, diseño y aplicación de algoritmos basados en redes neuronales artificiales multiclase, recomendación y transformer con capas ocultas para la resolución de problemas complejos y la extracción de características y patrones relevantes en grandes conjuntos de datos mediante el indicador precisión de la clasificación del algoritmo.

Definición conceptual: Sistema de selección de contratistas

Para Oyewole B. (2018), el proceso de selección de contratistas es una metodología rigurosa y organizada que se utiliza para analizar y contrastar las propuestas de diversos proveedores. Su propósito es elegir al contratista más capacitado para llevar a cabo las tareas del proyecto. Este proceso implica una evaluación minuciosa de las habilidades, experiencia y capacidades de los proveedores, con el fin de tomar una decisión fundamentada y obtener los mejores resultados en la ejecución del proyecto.

Definición operacional: Sistema de selección de contratistas

Según Oyewole B. (2018), el conjunto de pasos y criterios utilizados por la empresa para identificar, evaluar y seleccionar a los contratistas más adecuados para un proyecto específico, siendo los criterios de selección en las dimensiones Cartera de clientes, con el indicador Relación mercantil con otras empresas; dimensión Evaluación crediticia, con el indicador Salud crediticia a nivel de riesgo; dimensión Experiencia real, con el indicador Servicios relacionados

4.4. Cuadro de operacionalización de variables

Tabla 1
Operacionalización de la V.I. - Modelo Deep learning

Variable	Dimensión	Indicador	Valoración	Instrumento
Modelo Deep Learning	Clasificación por redes neuronales artificiales multiclase	-Precisión de la clasificación	1. Muy malo [0 – 49]	Guía de observación
	Clasificación por algoritmos de recomendación	-Precisión de la clasificación	2. Malo [50 – 84]	
	Clasificación por algoritmo transformer	-Precisión de la clasificación	3. Bueno [85 – 100]	

Nota. Cuadro de elaboración propia.

Tabla 2
Operacionalización de la V.D. - Sistema de selección de contratistas

Variable	Dimensión	Indicador	Valoración Indicador	Valoración variable	Instrumento
Sistema de Selección de Contratistas	Cartera de clientes	-Relación mercantil con otras empresas	1. Bajo [0 – 4] 2. Medio [5 – 7] 3. Alto [8 – 10]	1. Rechazado [0 – 49]	Ficha de Recolección de datos
	Evaluación crediticia	-Salud crediticia a nivel de riesgo	2. Medio [5 – 7] 3. Alto [8 – 10]	2. Observado [50 – 84] 3. Aceptado [85 – 100]	
	Experiencia real	-Servicios relacionados	1. Bajo [0 – 27] 2. Medio [28 – 54] 3. Alto [55 – 80]		

Nota. Cuadro de elaboración propia.

CAPÍTULO V:

METODOLOGÍA DE INVESTIGACIÓN

5.1. Enfoque de la investigación

Fue cuantitativo, debido a que es un enfoque metodológico que se utilizó en la recolección y el análisis de datos numéricos para examinar fenómenos y establecer relaciones entre variables, además se caracteriza por su rigor y objetividad, y se basa en técnicas estadísticas para realizar inferencias y comprobar hipótesis (Creswell & Creswell, 2018).

5.2. Tipo y nivel de investigación

5.2.1. Tipo de Investigación

La investigación fue del tipo aplicada, que es un tipo de investigación que se centró en resolver problemas prácticos y generar soluciones concretas para mejorar los procesos en cuanto a tiempos y el funcionamiento de diferentes áreas de la empresa. A diferencia de la investigación básica, que busca aumentar el conocimiento teórico sobre un tema, la investigación aplicada se orienta hacia la aplicación y utilización de ese conocimiento en contextos específicos (Fraenkel et al., 2022).

5.2.2. Nivel de Investigación

El nivel fue descriptivo y explicativo, puesto que el estudio se enfocó en describir, identificar y analizar la relación causa efecto de la variable de estudio. Este enfoque tiene

como objetivo describir con precisión y sistemáticamente una población, situación o fenómeno. Puede responder a preguntas de qué, dónde, cuándo y cómo, pero no a preguntas de por qué. Por otro lado, la investigación explicativa es un método de investigación que explora por qué ocurre algo cuando hay información limitada disponible, lo cual determina cómo o por qué está ocurriendo un fenómeno en particular y predecir ocurrencias futuras.(Hernández-Sampieri & Mendoza, 2018).

5.3. Métodos y diseño de investigación

5.3.1. Métodos de Investigación

El método empleado fue el hipotetico-deductivo puesto que se formularon hipótesis basadas en la teoría existente y luego diseñan estudios para poner a prueba estas hipótesis. Este proceso implicó producir predicciones específicas a partir de premisas generales y, posteriormente, realizar experimentos o estudios observacionales para recolectar datos que permitan confirmar o refutar dichas hipótesis (Popper, 2008)

5.3.2. Diseño de la Investigación

El diseño de la investigación fue experimental, longitudinal y preexperimental, debido a que se estableció la relación causa-efecto entre variables. Este tipo de diseño es útil para explorar patrones y tendencias en los datos y puede proporcionar información valiosa sobre las asociaciones entre variables en una población dada.

A continuación se presenta el diseño preexperimental que se aplicó en la presente investigación, así como los elementos que lo conforman.

E -> G1: O1 X O2

Donde:

O1 : Pre test.

O2 : Post test.

G1 : Grupo experimental .

X : Método de resolución de problemas.

5.4. Población y muestra de la investigación

5.4.1. Población

La población estuvo compuesta por 213 expedientes de contratistas que se extrajeron de las unidades de logística de Tacna, Ilo y Moquegua. Para Babbie (2018) la población de investigación se refiere al conjunto de individuos, objetos o eventos que comparten características comunes y que serán objeto de estudio en la investigación.

Tabla 3

Población de expedientes de contratistas 2020 y 2021

Grupo	Proyecto de obras	Expedientes	Porcentaje (%)
1	Electricidad	20	9,39
2	Construcción civil	72	33,80
3	Misceláneos	28	13,15
4	Metal mecánico	93	43,66
Total expedientes de contratistas		213	100,00

Nota. Cuadro de elaboración propia.

5.4.2. Muestra

El presente estudio hizo uso de la muestra censal, Soto Abanto (2018) lo define como un procedimiento bien organizado de recopilación, registro y análisis de información, donde se utiliza el recuento oficial y completo de la población; en tanto, la investigación hará uso del 100% de la población.

5.5. Técnicas e instrumentos de recolección de datos

5.5.1. Técnicas

La técnica a emplear fue el análisis documental, la cual es una técnica para recopilar información de diversas fuentes y utilizarla para comprender y analizar procedimientos y normativas sobre selección de contratistas. Según Hernández-Sampieri & Mendoza (2018) las técnicas son herramientas y métodos serán utilizados para obtener

información específica de una fuente o grupo de fuentes para recopilar la información necesaria y tomar decisiones informadas.

5.5.2. Instrumentos

Sobre el instrumento se utilizó la ficha de recolección de datos. Según Hernández-Sampieri & Mendoza (2018) es un instrumento utilizado en la investigación para recopilar y organizar la información relevante de manera sistemática. Esta herramienta proporciona una estructura para registrar los datos obtenidos durante el proceso de recolección, además la ficha de recolección de datos suele tener un formato tabular o estructurado, donde se registran diferentes variables, categorías o aspectos a investigar.

Al ser un estudio de diseño experimental, la medición para la variable dependiente "Sistema de selección de contratistas" estuvo compuesta por una ficha de evaluación para el expediente del contratista que constó de:

- a) Dimensión cartera de clientes
Indicadores: Relación mercantil con otras empresas
- b) Dimensión evaluación crediticia
Indicadores: Salud crediticia a nivel de riesgo
- c) Dimensión experiencia real
Indicador: Servicios relacionados

5.5.3. Validez y confiabilidad

La validez se refiere a la capacidad de un instrumento de medir lo que se supone que mide, mientras que la confiabilidad se refiere a la consistencia y estabilidad de los resultados obtenidos al aplicar el instrumento en diferentes momentos y con diferentes sujetos (Hernández-Sampieri & Mendoza, 2018)

Siendo los siguientes expertos Doctores en sistemas e investigadores RENACYT, los que validaron la ficha de recolección de datos.

Tabla 4*Resultado del juicio de expertos*

N°	Apellidos y nombres	Grado	Juicio
1	Jimenez Castilla, Juan Ubaldo	Doctor en ingeniería de Sistemas	Instrumentos favorables para su aplicación
2	Flores Garcia, Anibal Fernando	Doctor en Ciencias de computación	Instrumentos aplicables para el estudio
3	Silva Delgado, Otoniel	Doctor en ingeniería de Sistemas	Instrumentos suficientes, relevantes y claros para su aplicación

Nota. Elaboración propia

De la confiabilidad está no aplica para el presente estudio puesto que el instrumento es una ficha de recolección de datos, por tanto, no es aplicable el alfa de Cronbach, KR20 o KR21.

5.5.4. Procesamiento y análisis de datos

Para el correcto procesamiento y análisis de los datos se realizarán los siguientes pasos:

- a) Diseño de la ficha de recolección de datos: Para probar las hipótesis, alcanzar los objetivos y responder las preguntas de investigación.
- b) Elegir los niveles o modalidades de manipulación de las variables independientes y traducirlos en tratamientos experimentales.
- c) Seguimiento de la población: Se hizo un seguimiento a la población en torno a la recolección de las fichas proveniente de las unidades logística de la empresa ubicados en los departamentos de Tacna Ilo y Moquegua.
- d) Preparación de los datos: Los datos fueron ingresados en SPSS 27 para su procesamiento, en donde se verificó que los datos estén completos y sin errores, y se ajustaron al formato adecuado para su análisis.
- e) Análisis de datos descriptivo: Se describieron las características de las variables de estudio, como su distribución, media, desviación estándar y otras medidas de resumen, realizando el análisis descriptivo en SPSS 27. Esto permitió una mejor comprensión de los datos y la identificación de patrones y tendencias.

- f) Análisis de datos inferenciales: Para determinar el estadígrafo correspondiente, se realizó una prueba de normalidad en SPSS 27, posteriormente se aplicó el estadístico paramétrico regresión lineal simple.

5.5.5. Ética en la investigación

Para Smith et al. (2016), el espíritu y los métodos de la ciencia moderna están respaldados por la libertad y la búsqueda de la verdad y el respeto por todas las formas de vida y el medio ambiente; Todo esto es coherente con los valores de los científicos y se sustenta en la integridad, la reverencia a la libertad y los compromisos con la sostenibilidad.

La ciencia y sus fundamentos éticos están amenazados por el engaño y la deshonestidad. Estos elementos que son el lado oscuro de la ciencia se manifiestan como mala conducta de investigación, como el plagio que debe entenderse y evitarse de manera asidua.

Por tanto, el autor se comprometió con los principios y normas éticas necesarias para proteger los derechos y el bienestar de los participantes, y asegurar la calidad e integridad de los resultados. Para ello, se siguió el código de ética para la investigación de la Universidad Alas Peruanas, el cual se enfoca en la honestidad, buena fe, libertad y responsabilidad de los creadores, el bien común, el cuidado de la vida, el medio ambiente, el respeto de la biodiversidad, la difusión del conocimiento, la revisión independiente y la transparencia.

CAPÍTULO VI:

RESULTADOS

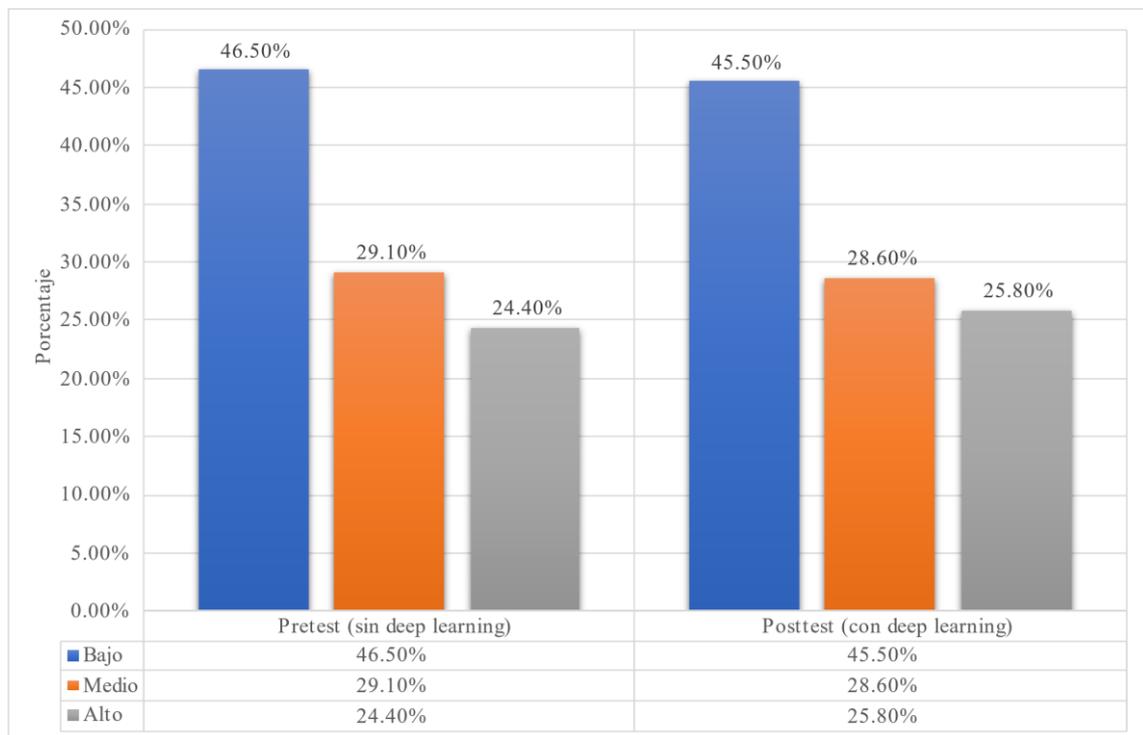
6.1. Análisis descriptivo

En esta fase inicial del análisis, se presentan los resultados descriptivos de los indicadores pertenecientes a la variable “Sistema de Selección de Contratistas” en pretest y posttest, para ello, se examinó la distribución de los datos en términos de frecuencias (fr) y porcentajes (%) identificando las posibles diferencias entre ambos. Los niveles empleados en los indicadores fueron de “Bajo”, ”Medio” y “Alto” con el fin de dar interpretación a los resultados descriptivos, así mismo para la variable “Sistema de Selección de Contratistas” se emplearon los niveles "Rechazado", "Observado" y "Aceptado", que reflejan las decisiones tomadas por el comité evaluador sobre los expedientes de los contratistas.

Acompañando este análisis descriptivo se realizaron interpretaciones basadas en las tablas y figuras, lo que permite comprender de manera detallada cada indicador y lo que significa la aplicación del Modelo Deep Learning en el proceso de selección de contratistas en el sector minero de Tacna. Además estos resultados descriptivos obtenidos contribuyeron a la comprensión de los efectos de la aplicación de esta tecnología en el contexto específico de la industria minera, brindando información relevante para la toma de decisiones y la mejora continua de este importante proceso que involucra millones de dólares en servicios especializados y de alta calidad en las empresas mineras del Perú y el mundo.

Tabla 5*Frecuencias de D1. Cartera de clientes - i. Relación mercantil con otras empresas*

Nivel	Pretest (sin deep learning)		Posttest (con deep learning)	
	fr.	%	fr.	%
Bajo	99	46.50%	97	45.50%
Medio	62	29.10%	61	28.60%
Alto	52	24.40%	55	25.80%
Total	213	100.00%	213	100.00%

Figura 8*Frecuencias en % de D1. Cartera de clientes - i. Relación mercantil con otras empresas***Interpretación de la tabla 5 y figura 8:**

Los resultados obtenidos tras analizar la distribución de los niveles del indicador "i. Relación mercantil con otras empresas" de la dimensión "D1. Cartera de clientes" muestran ligeras variaciones entre el pretest y el posttest; estas observaciones sugieren que la incorporación del Modelo Deep Learning en la evaluación del indicador "i. Relación mercantil con otras empresas" produce resultados prácticamente similares a las evaluaciones de expedientes realizados por el comité de la empresa minera.

Este hallazgo es significativo, ya que indica que el Modelo Deep Learning tiene un desempeño muy alto, logrando una notable aproximación a las decisiones tomadas por el comité en sus evaluaciones, por tanto se destaca que esta consistencia entre los resultados del modelo y las evaluaciones del comité es un indicio de la eficacia y utilidad del modelo Deep Learning en el análisis de la relación mercantil con otras empresas para la dimensión cartera de clientes, perteneciente al sistema de selección de contratistas del sector minero.

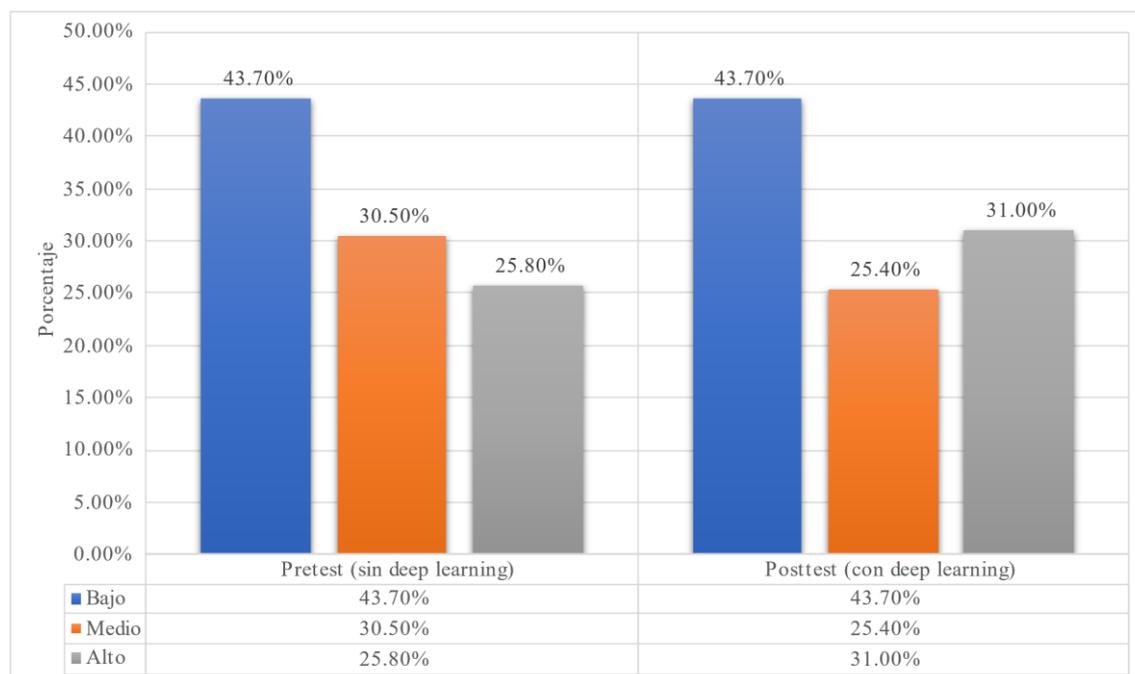
Tabla 6

Frecuencias de D2. Evaluación crediticia - i. Salud crediticia a nivel de riesgo

Nivel	Pretest (sin deep learning)		Posttest (con deep learning)	
	fr.	%	fr.	%
Bajo	93	43.70%	93	43.70%
Medio	65	30.50%	54	25.40%
Alto	55	25.80%	66	31.00%
Total	213	100.00%	213	100.00%

Figura 9

Frecuencias en % de D2. Evaluación crediticia - i. Salud crediticia a nivel de riesgo



Interpretación de la tabla 6 y figura 9:

Los resultados obtenidos del análisis de la distribución de los niveles del indicador "i. Salud crediticia a nivel de riesgo" de la dimensión "D2. Evaluación crediticia" muestran ligeras variaciones entre el pretest y el posttest; estos hallazgos sugieren que la aplicación del Modelo Deep Learning en el indicador "i. Salud crediticia a nivel de riesgo" arroja resultados prácticamente similares a las evaluaciones realizadas por el comité de la empresa minera en relación con los expedientes de los contratistas evaluados por dicho comité.

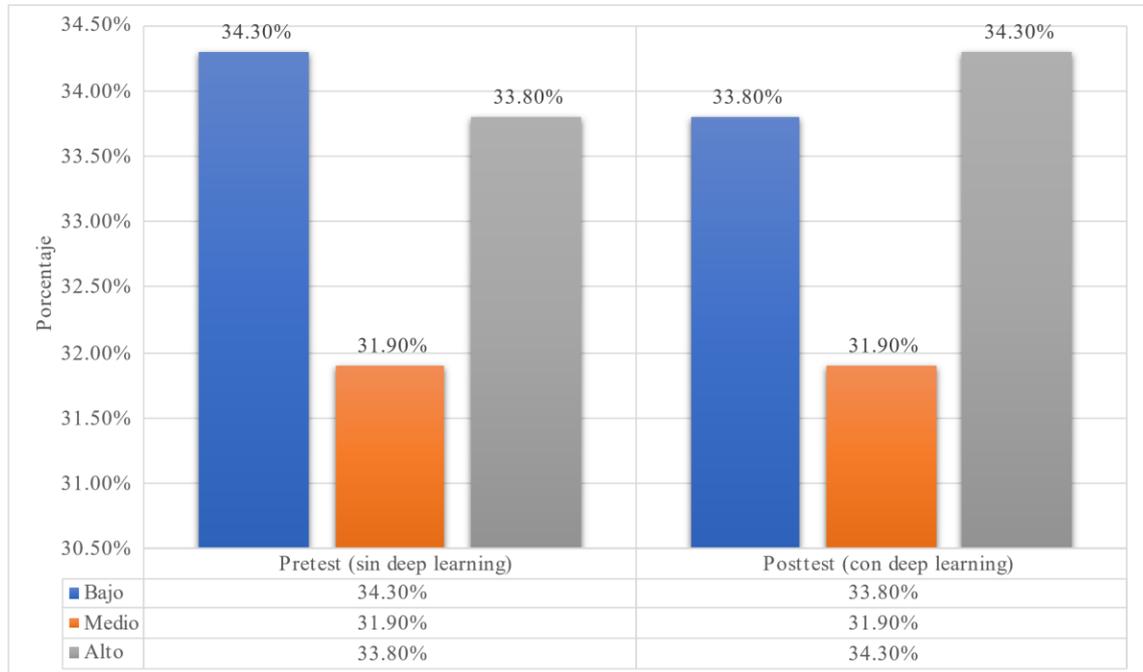
Esta cercana similitud entre los resultados del modelo y las evaluaciones humanas indica que el Modelo Deep Learning exhibe un desempeño excepcional, al aproximarse considerablemente a las decisiones tomadas por el comité evaluador, este descubrimiento es de gran relevancia, ya que resalta la efectividad y precisión del Modelo Deep Learning en el análisis de la salud crediticia a nivel de riesgo para la dimensión evaluación crediticia, perteneciente al sistema de selección de contratistas del sector minero.

Tabla 7
Frecuencias de D3. Experiencia real - i. Servicios relacionados

Nivel	Pretest (sin deep learning)		Posttest (con deep learning)	
	fr.	%	fr.	%
Bajo	73	34.30%	72	33.80%
Medio	68	31.90%	68	31.90%
Alto	72	33.80%	73	34.30%
Total	213	100.00%	213	100.00%

Figura 10

Frecuencias en % de D3. Experiencia real - i. Servicios relacionados



Interpretación de la tabla 7 y figura 10:

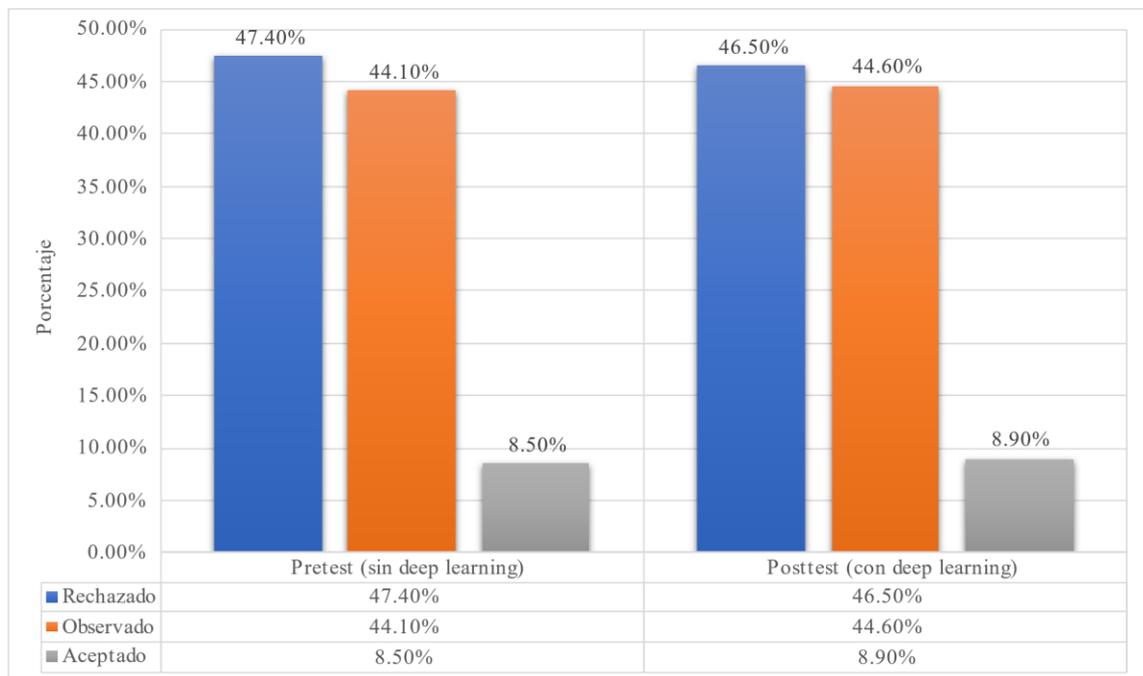
Los resultados obtenidos del análisis de la distribución de los niveles del indicador "i. Servicios relacionados" en la dimensión "D3. Experiencia real" revelan ligeras variaciones entre el pretest y el posttest, estos hallazgos sugieren que la aplicación del Modelo Deep Learning en el indicador "i. Servicios relacionados" arroja resultados prácticamente similares a las evaluaciones realizadas por el comité de la empresa minera en relación con los expedientes de los contratistas.

La cercana similitud entre los resultados del modelo y las evaluaciones humanas indica que el Modelo Deep Learning exhibe un desempeño excepcional al aproximarse de manera significativa a las decisiones tomadas por el comité evaluador; este hallazgo es de gran importancia, ya que resalta la efectividad y precisión del modelo Deep Learning en el análisis de los servicios relacionados para la dimensión de la experiencia real de los contratistas, perteneciente al sistema de selección de contratistas del sector minero.

Tabla 8
Frecuencias del Sistema de selección de contratistas

Nivel	Pretest (sin deep learning)		Posttest (con deep learning)	
	fr.	%	fr.	%
Rechazado	101	47.40%	99	46.50%
Observado	94	44.10%	95	44.60%
Aceptado	18	8.50%	19	8.90%
Total	213	100.00%	213	100.00%

Figura 11
Frecuencias en % del Sistema de selección de contratistas



Interpretación de la tabla 8 y figura 11:

El análisis de la tabla revela la distribución de las decisiones del comité sobre los expedientes de los contratistas antes y después de la implementación del modelo Deep Learning, en donde se observa que las proporciones de los expedientes rechazados, observados y aceptados apenas varían entre el pretest y el posttest; esto sugiere que la incorporación del modelo Deep Learning en el sistema de selección de contratistas no ha generado cambios drásticos en las decisiones tomadas por el comité evaluador.

Por tanto, la similitud entre pretest y posttest indica que el modelo Deep Learning ha sido capaz de producir resultados cercanos a las evaluaciones realizadas por el comité de la empresa minera, siendo esta consistencia muy prometedora ya que muestra que el modelo es capaz de capturar patrones y características importantes en los expedientes de los contratistas para realizar recomendaciones acertadas.

Cabe aclarar que la aplicación del modelo Deep Learning en el Sistema de selección de contratistas de la empresa minera, no tiene como fin sustituir al comité evaluador de los expedientes, los cuales cuentan con todas las aptitudes y capacidades para desarrollar de la mejor manera su labor, si no por el contrario los resultados del modelo Deep Learning sirven para realizar un pre filtro en la evaluación de los expedientes, considerando el alto índice de rechazados u observados y pocos en el nivel aceptado, agilizando así la labor de evaluación de toma de decisiones del comité, mejorando su eficiencia y efectividad.

6.2. Análisis inferencial

Prueba de normalidad de datos

Es una herramienta estadística utilizada para determinar si una muestra de datos sigue una distribución normal o no, considerando que el tipo de distribución es importante porque muchos métodos y pruebas estadísticas se basan en su resultado, por ello se emplearon los siguientes parámetros.

Regla para la toma de decisión

- Significancia: $\alpha = 5\%$; $\alpha = 0,05$
- Si p-valor (Sig. asintótica bilateral) es $< \alpha$, por tanto se acepta H_a .
- Si p-valor (Sig. asintótica bilateral) es $\geq \alpha$, por tanto se acepta H_0 .

Hipótesis:

- H_0 ; Se cuenta con distribución normal en los datos.
- H_a ; No se cuenta con distribución normal en los datos.

Tabla 9
Resultado de la prueba de normalidad de datos

Variable/Dimensión	Kolmogórov-Smirnov			Shapiro-Wilk		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
Sistema de selección de contratistas (Sin Deep Learning)	0.088	213	0.074	0.961	213	0.073
D1. Cartera de clientes	0.126	213	0.075	0.945	213	0.071
D2. Evaluación	0.128	213	0.056	0.923	213	0.054
D3. Experiencia real	0.076	213	0.065	0.95	213	0.06
Sistema de selección de contratistas (Con Deep Learning)	0.090	213	0.073	0.957	213	0.075
D1. Cartera de clientes	0.121	213	0.074	0.944	213	0.069
D2. Evaluación	0.122	213	0.052	0.923	213	0.056
D3. Experiencia real	0.079	213	0.066	0.946	213	0.070

Interpretación:

La tabla 9 presenta los resultados de la prueba de Kolmogórov-Smirnov y Shapiro-Wilk para las variables y sus dimensiones; considerando que la muestra poblacional del estudio es mayor a 50, se tomó en cuenta solamente los resultados de la prueba de Kolmogórov-Smirnov, donde la evidencia demuestra que los datos de la columna “Sig.” (p-valor) son mayores que el nivel de significancia 0,05, por tanto se rechaza la H_a y acepta H_o , afirmando que los datos siguen una distribución normal, lo que permitió aplicar la prueba paramétrica regresión lineal simple.

Prueba de Hipótesis

Para realizar el análisis de cada prueba de hipótesis, se definen los siguientes parámetros que ayudaron a interpretar los resultados del estadístico paramétrico regresión lineal simple:

- a. Se plantearon las hipótesis de investigación nula y alterna.
- b. Nivel de sig. igual a 0,05
- c. Estadístico paramétrico regresión lineal simple

$$y = ax + b;$$

y=variable dependiente; a=pendiente;
x=variable independiente o predictora; b=intersección

- d. Criterio para la toma de decisión:
 - Se acepta la hipótesis alterna y se rechaza la nula; si p-valor < 0,05
 - Se acepta la hipótesis nula y se rechaza la alterna; si p-valor > 0,05

Prueba de hipótesis general

Ho. No existe influencia del modelo Deep learning en el sistema de selección de contratistas en el sector minero, Tacna 2023

Ha. Existe influencia del modelo Deep learning en el sistema de selección de contratistas en el sector minero, Tacna 2023

Tabla 10

Resumen del modelo para el Sistema de selección de contratistas

Modelo	R	R cuadrado	R cuadrado ajustado	Error estándar de la estimación
1	0.999 ^a	0.998	0.998	0.97834

Nota. a. Predictores: (Constante), Sistema de selección de contratistas (Con Deep Learning)

En esta tabla, los valores de “R cuadrado y R cuadrado” ajustado son muy cercanos a 1, lo que sugiere que el modelo de regresión lineal simple explica aproximadamente el 99.8% de la variabilidad de la variable dependiente "Sistema de selección de contratistas" cuando se considera el predictor "Sistema de selección de contratistas (Con Deep Learning)". Además, el error estándar de la estimación es relativamente bajo, lo que indica que el modelo se ajusta bien a los datos.

Tabla 11
ANOVA^a para el Sistema de selección de contratistas

Modelo	Suma de cuadrados	gl	Media cuadrática	F	Sig.
Regresión	123931.477	1	123931.477	129479.192	0.000 ^b
Residuo	201.959	211	0.957		
Total	124133.437	212			

Nota. a. Variable dependiente: Sistema de selección de contratistas (Sin Deep Learning)

b. Predictores: (Constante), Sistema de selección de contratistas (Con Deep Learning)

En la tabla de ANOVA, la columna “Sig.” en el “modelo de regresión” es de 0.000, siendo menor a la significancia de 0.05, lo que indica que la prueba de hipótesis es estadísticamente significativa. Por tanto, se rechaza la hipótesis nula (Ho) y acepta la alternativa (Ha), y se puede concluir que existe una influencia significativa del modelo Deep Learning en el sistema de selección de contratistas en el sector minero de Tacna en 2023.

Tabla 12
Coeficientes^a para el Sistema de selección de contratistas

Modelo	Coeficientes no estandarizados		Coeficientes estandarizados		Sig.
	B	Desv. Error	Beta	t	
(Constante)	0.404	0.156	-	2.586	0.010
Sistema de selección de contratistas (Con Deep Learning)	0.996	0.003	0.999	359.832	0.000

Nota. a. Variable dependiente: Sistema de selección de contratistas (Sin Deep Learning)

En la tabla de coeficientes, se observa que el coeficiente B para "Sistema de selección de contratistas (Con Deep Learning)" es de 0.996. Esto sugiere que hay una fuerte relación positiva entre el modelo Deep Learning y el sistema de selección de contratistas. Y el valor p (0.000) es menor que el nivel de significancia estándar de 0.05, lo que indica que el coeficiente es estadísticamente significativo, aceptando la hipótesis alternativa (Ha) y rechazando la hipótesis nula (Ho).

Interpretación de resultados para la hipótesis general:

Los resultados del análisis de regresión lineal simple indican que el modelo Deep Learning tiene una influencia significativa y positiva en el sistema de selección de contratistas en el sector minero de Tacna en 2023. Por tanto, se acepta la hipótesis alternativa (Ha) y se rechaza la hipótesis nula (Ho), concluyendo que el modelo Deep Learning influye positivamente en el proceso de selección de contratistas en este sector.

Prueba de hipótesis específica 1

Ho. No existe influencia del modelo Deep learning en la cartera de clientes de los contratistas en el sector minero, Tacna 2023

Ha. Existe influencia del modelo Deep learning en la cartera de clientes de los contratistas en el sector minero, Tacna 2023

Tabla 13

Resumen del modelo para la Cartera de clientes

Modelo	R	R cuadrado	R cuadrado ajustado	Error estándar de la estimación
1	0.994 ^a	0.988	0.988	0.32167

Nota. a. Predictores: (Constante), D1. Cartera de clientes (Con Deep Learning)

En esta tabla, los valores de “R cuadrado y R cuadrado ajustado” son altos, lo que indica que el modelo de regresión lineal simple explica aproximadamente el 98.8% de la variabilidad de la dimensión (D1) "Cartera de clientes" cuando se considera el predictor "D1. Cartera de clientes (Con Deep Learning)". Además, el error estándar de la estimación es relativamente bajo, lo que sugiere que el modelo se ajusta bien a los datos.

Tabla 14

ANOVA^a para la Cartera de clientes

Modelo	Suma de cuadrados	gl	Media cuadrática	F	Sig.
Regresión	1836.083	1	1836.083	17744.448	0.000 ^b
Residuo	21.833	211	0.103		
Total	1857.915	212			

Nota. a. Variable dependiente: D1. Cartera de clientes (Sin Deep Learning)

b. Predictores: (Constante), D1. Cartera de clientes (Con Deep Learning)

En la tabla de ANOVA, la columna “Sig.” en el “modelo de regresión” es de 0.000, siendo menor a la significancia de 0.05, lo que indica que la prueba de hipótesis es estadísticamente significativa. Por tanto, se rechaza la hipótesis nula (Ho) y acepta la hipótesis alterna (Ha), y se puede concluir que existe una influencia significativa del modelo Deep Learning en la cartera de clientes de los contratistas en el sector minero de Tacna en 2023.

Tabla 15
Coeficientes ^a para la Cartera de clientes

Modelo	Coeficientes no estandarizados		Coeficientes estandarizados		
	B	Desv. Error	Beta	t	Sig.
(Constante)	0.045	0.042	-	1.06	0.044
D1. Cartera de clientes (Con Deep Learning)	0.965	0.007	0.994	133.208	0.000

Nota. a. Variable dependiente: D1. Cartera de clientes (Sin Deep Learning)

En la tabla de coeficientes, se observa que el coeficiente B para "D1. Cartera de clientes (Con Deep Learning)" es de 0.965. Esto sugiere que hay una fuerte relación positiva entre el modelo Deep Learning y la cartera de clientes de los contratistas en el sector minero. Y el valor p (0.000) es menor que el nivel de significancia estándar de 0.05, lo que indica que el coeficiente es estadísticamente significativo, aceptando la hipótesis alternativa (Ha) y rechazando la hipótesis nula (Ho).

Interpretación de resultados para la hipótesis específica 1:

Los resultados del análisis de regresión lineal simple indican que el modelo Deep Learning tiene una influencia significativa y positiva en la cartera de clientes de los contratistas en el sector minero de Tacna en 2023. Por tanto, se acepta la hipótesis alternativa (Ha) y se rechaza la hipótesis nula (Ho), concluyendo que el modelo Deep Learning influye positivamente en la cartera de clientes de los contratistas en este sector.

Prueba de hipótesis específica 2

Ho. No existe influencia del modelo Deep learning en la evaluación crediticia de los contratistas en el sector minero, Tacna 2023

Ha. Existe influencia del modelo Deep learning en la evaluación crediticia de los contratistas en el sector minero, Tacna 2023

Tabla 16

Resumen del modelo para la Evaluación crediticia

Modelo	R	R cuadrado	R cuadrado ajustado	Error estándar de la estimación
1	0.992 ^a	0.983	0.983	0.40622

Nota. a. Predictores: (Constante), D2. Evaluación crediticia (Con Deep Learning)

En esta tabla, los valores de “R cuadrado y R cuadrado ajustado” son altos, lo que indica que el modelo de regresión lineal simple explica aproximadamente el 98.3% de la variabilidad de la variable dependiente "Evaluación crediticia" cuando se considera el predictor "D2. Evaluación crediticia (Con Deep Learning)". Además, el error estándar de la estimación es relativamente bajo, lo que sugiere que el modelo se ajusta bien a los datos.

Tabla 17

ANOVA^a para la Evaluación crediticia

Modelo	Suma de cuadrados	gl	Media cuadrática	F	Sig.
Regresión	2043.502	1	2043.502	12383.921	0.000 ^b
Residuo	34.818	211	0.165		
Total	2078.319	212			

Nota. a. Variable dependiente: D2. Evaluación crediticia (Sin Deep Learning)

b. Predictores: (Constante), D2. Evaluación crediticia (Con Deep Learning)

En la tabla de ANOVA, la columna “Sig.” en el “modelo de regresión” es de 0.000, siendo menor a la significancia de 0.05, lo que indica que la prueba de hipótesis es estadísticamente significativa. Por tanto, se rechaza la hipótesis nula (Ho) y se acepta la hipótesis alterna (Ha), y se puede concluir que existe una influencia significativa del

modelo Deep Learning en la evaluación crediticia de los contratistas en el sector minero de Tacna en 2023.

Tabla 18
Coefficientes ^a para la Evaluación crediticia

Modelo	Coeficientes no estandarizados		Coeficientes estandarizados		
	B	Desv. Error	Beta	t	Sig.
(Constante)	0.094	0.051	-	1.836	0.038
D1. Cartera de clientes (Con Deep Learning)	0.941	0.008	0.992	111.283	0.000

Nota. a. Variable dependiente: D2. Evaluación crediticia (Sin Deep Learning)

En la tabla de coeficientes, se observa que el coeficiente B para "D2. Evaluación crediticia (Con Deep Learning)" es de 0.941. Esto sugiere que hay una fuerte relación positiva entre el modelo Deep Learning y la evaluación crediticia de los contratistas en el sector minero. Y el valor p (0.000) es menor que el nivel de significancia estándar de 0.05, lo que indica que el coeficiente es estadísticamente significativo, aceptando la hipótesis alternativa (Ha) y rechazando la hipótesis nula (Ho).

Interpretación de resultados para la hipótesis específica 2:

Los resultados del análisis de regresión lineal simple indican que el modelo Deep Learning tiene una influencia significativa y positiva en la evaluación crediticia de los contratistas en el sector minero de Tacna en 2023. Por tanto, se acepta la hipótesis alternativa (Ha) y se rechaza la hipótesis nula (Ho), concluyendo que el modelo Deep Learning influye positivamente en la evaluación crediticia de los contratistas en este sector.

Prueba de hipótesis específica 3

Ho. No existe influencia del modelo Deep learning en la experiencia real de los contratistas en el sector minero, Tacna 2023

Ha. Existe influencia del modelo Deep learning en la experiencia real de los contratistas en el sector minero, Tacna 2023

Tabla 19

Resumen del modelo para la Experiencia real

Modelo	R	R cuadrado	R cuadrado ajustado	Error estándar de la estimación
1	.999 ^a	0.999	0.999	0.92407

Nota. a. Predictores: (Constante), D3. Experiencia real (Con Deep Learning)

En esta tabla, los valores de “R cuadrado y R cuadrado ajustado” son muy altos, lo que indica que el modelo de regresión lineal simple explica aproximadamente el 99.9% de la variabilidad de la variable dependiente "Experiencia real" cuando se considera el predictor "D3. Experiencia real (Con Deep Learning)". Además, el error estándar de la estimación es relativamente bajo, lo que sugiere que el modelo se ajusta muy bien a los datos.

Tabla 20

ANOVA^a para la Experiencia real

Modelo	Suma de cuadrados	gl	Media cuadrática	F	Sig.
Regresión	123651.16	1	123651.16	144806.883	0.000 ^b
Residuo	180.174	211	0.854		
Total	123831.333	212			

Nota. a. Variable dependiente: D3. Experiencia real (Sin Deep Learning)

b. Predictores: (Constante), D3. Experiencia real (Con Deep Learning)

En la tabla de ANOVA, la columna “Sig.” en el “modelo de regresión” es de 0.000, siendo menor a la significancia de 0.05, lo que indica que la prueba de hipótesis es estadísticamente significativa. Por tanto, se rechaza la hipótesis nula (Ho) y se acepta la hipótesis alterna (Ha), y se puede concluir que existe una influencia significativa del

modelo Deep Learning en la experiencia real de los contratistas en el sector minero de Tacna en 2023.

Tabla 21
Coefficientes ^a para la Experiencia real

Modelo	Coeficientes no estandarizados		Coeficientes estandarizados		
	B	Desv. Error	Beta	t	Sig.
(Constante)	0.17	0.125	-	1.364	0.174
D3. Experiencia real (Con Deep Learning)	0.997	0.003	0.999	380.535	0.000

Nota. a. Variable dependiente: D3. Experiencia real (Sin Deep Learning)

En la tabla de coeficientes, se observa que el coeficiente B para "D3. Experiencia real (Con Deep Learning)" es de 0.997. Esto sugiere que hay una fuerte relación positiva entre el modelo Deep Learning y la experiencia real de los contratistas en el sector minero. Y el valor p (0.000) es menor que el nivel de significancia estándar de 0.05, lo que indica que el coeficiente es estadísticamente significativo, aceptando la hipótesis alternativa (Ha) y rechazando la hipótesis nula (Ho).

Interpretación de resultados para la hipótesis específica 3:

los resultados del análisis de regresión lineal simple indican que el modelo Deep Learning tiene una influencia significativa y positiva en la experiencia real de los contratistas en el sector minero de Tacna en 2023. Por tanto, se acepta la hipótesis alternativa (Ha) y se rechaza la hipótesis nula (Ho), concluyendo que el modelo Deep Learning afecta positivamente la experiencia real de los contratistas en este sector.

CAPÍTULO VII:

DISCUSIÓN DE RESULTADOS

7.1. Discusión de resultados

Sobre el objetivo general, Determinar la influencia del modelo Deep learning en el sistema de selección de contratistas en el sector minero, Tacna 2023; se determinó según la tabla 12 que el estadístico regresión lineal simple, en sus coeficientes, se observó que el coeficiente B para "Sistema de selección de contratistas (Con Deep Learning)" es de 0.996, demostrando que existe una fuerte relación entre el modelo Deep Learning y el sistema de selección de contratistas, siendo el valor p (0.000) menor al nivel de significancia de 0.05, lo que significa que el coeficiente es estadísticamente significativo. Por tanto, se aceptó la hipótesis alternativa (Ha) y se rechazó la hipótesis nula (Ho), concluyendo que el modelo Deep Learning influye positivamente el proceso de selección de contratistas en este sector.

Estos resultados convergen con lo hallado por Taylan et al. (2018) quienes explicaron como el Deep Learning y Big Data inciden en la selección de contratistas para proyectos de construcción mediante herramientas de consenso, resultando que los algoritmos Deep learning son útiles al momento de seleccionar contratistas por criterios cuantificables sin intervención humana para los proyectos de construcción; del mismo Kizil & Knights (2020) analizaron la aplicación de la inteligencia artificial en la selección de proveedores en la industria minera, concluyendo que el uso de la inteligencia artificial ha tenido gran influencia en la selección de proveedores mineros.

En consecuencia, debido a la discusión realizada, se ha demostrado que el modelo Deep Learning tiene una influencia significativa y positiva en el sistema de selección de contratistas en el sector minero. Por tanto el modelo Deep Learning ha sido capaz de producir resultados cercanos a las evaluaciones realizadas por el comité de la empresa minera, siendo esta consistencia muy prometedora ya que muestra que el modelo es capaz de capturar patrones y características importantes en los expedientes de los contratistas para realizar recomendaciones acertadas.

Cabe discutir que la aplicación del modelo Deep Learning en el Sistema de selección de contratistas de la empresa minera, no tiene como fin sustituir al comité evaluador de los expedientes, los cuales cuentan con todas las aptitudes y capacidades para desarrollar de la mejor manera su labor, si no por el contrario los resultados del modelo Deep Learning sirven para realizar un pre filtro en la evaluación de los expedientes, considerando el alto índice de rechazados u observados y pocos en el nivel aceptado, agilizando así la labor de evaluación de toma de decisiones del comité, mejorando su eficiencia y efectividad.

Del primer objetivo específico, Especificar la influencia del modelo Deep learning en la Cartera de Clientes de los contratistas en el sector minero, Tacna 2023; se determinó según la tabla 15 que el estadístico regresión lineal simple, en sus coeficientes, se observó que el coeficiente B para "D1. Cartera de clientes (Con Deep Learning)" es de 0.965, demostrando que existe una fuerte relación entre el modelo Deep Learning y la cartera de clientes de los contratistas en el sector minero, siendo el valor p (0.000) menor al nivel de significancia de 0.05, lo que significa que el coeficiente es estadísticamente significativo. Por tanto, se aceptó la hipótesis alternativa (H_a) y se rechazó la hipótesis nula (H_0), concluyendo que el modelo Deep Learning influye positivamente en la cartera de clientes de los contratistas en este sector.

Estos resultados convergen con lo hallado por Nieto-Morote & Ruz-Vila (2022) aplicaron el enfoque Deep Learning para la toma de decisiones multicriterio en la selección de contratistas de construcción, demostrando las ventajas del uso de un algoritmo en la cartera de clientes de los contratistas; de igual manera García et al. (2021), desarrollaron un modelo de toma de decisiones híbrido para la selección de contratistas

en proyectos de construcción según el nivel de experiencia del contratista a través de su cartera de clientes, demostrando que el enfoque adaptativo difuso basado en IA brinda una mejor capacidad para seleccionar y clasificar a los contratistas en proyectos de construcción.

En consecuencia, debido a la discusión realizada, se ha demostrado que el modelo Deep Learning tiene una influencia significativa y positiva en la Cartera de Clientes de los contratistas en el sector minero. Por tanto se destaca la consistencia entre los resultados del modelo y las evaluaciones del comité como un indicio de la eficacia y utilidad del modelo Deep Learning en el análisis de la relación mercantil con otras empresas para la dimensión cartera de clientes, perteneciente al sistema de selección de contratistas del sector minero.

Del segundo objetivo específico, Evaluar la influencia del modelo Deep learning en la Evaluación crediticia de los contratistas en el sector minero, Tacna 2023; se determinó según la tabla 18 que el estadístico regresión lineal simple, en sus coeficientes, se observó que el coeficiente B para "D2. Evaluación crediticia (Con Deep Learning)" es de 0.941, demostrando que existe una fuerte relación entre el modelo Deep Learning y la evaluación crediticia de los contratistas en el sector minero, siendo el valor p (0.000) menor al nivel de significancia de 0.05, lo que significa que el coeficiente es estadísticamente significativo. Por tanto, se aceptó la hipótesis alternativa (Ha) y se rechazó la hipótesis nula (Ho), concluyendo que el modelo Deep Learning influye positivamente en la evaluación crediticia de los contratistas en este sector.

Estos resultados convergen con lo hallado por Vardin et al. (2021) aplicando la lógica difusa para manejar la incertidumbre y la subjetividad en el proceso de selección de contratistas, demostrando que el modelo integrado de Deep Learning brinda un apoyo efectivo en la evaluación de contratistas, los cuales también sugieren abordar el historial crediticio; también Rodríguez et al. (2020) utilizan un modelo de toma de decisiones para mejorar el procedimiento de selección de subcontratistas en proyectos de carreteras los cuales deben contar con un buen historial de crédito.

En consecuencia, debido a la discusión realizada, se ha demostrado que el modelo Deep Learning tiene una influencia significativa y positiva en la Evaluación crediticia de los contratistas en el sector minero. Por tanto Modelo Deep Learning exhibe un desempeño excepcional, al aproximarse considerablemente a las decisiones tomadas por el comité evaluador, este descubrimiento es de gran relevancia, ya que resalta la efectividad y precisión del Modelo Deep Learning en el análisis de la salud crediticia a nivel de riesgo para la dimensión evaluación crediticia, perteneciente al sistema de selección de contratistas del sector minero.

Del tercer objetivo específico, Demostrar la influencia del modelo Deep learning en la Experiencia real de los contratistas en el sector minero, Tacna 2023; se determinó según la tabla 21 que el estadístico regresión lineal simple, en sus coeficientes, se observó que el coeficiente B para "D3. Experiencia real (Con Deep Learning)" es de 0.997, demostrando que existe una fuerte relación entre el modelo Deep Learning y la experiencia real de los contratistas en el sector minero, siendo el valor p (0.000) menor al nivel de significancia de 0.05, lo que significa que el coeficiente es estadísticamente significativo. Por tanto, se aceptó la hipótesis alternativa (H_a) y se rechazó la hipótesis nula (H_0), concluyendo que el modelo Deep Learning afecta positivamente la experiencia real de los contratistas en este sector.

Estos resultados convergen con lo hallado por Benavides-Fernandez & Muñoz (2019) quienes propusieron un modelo de gestión para evaluar a las empresas contratistas del sector minero considerando su experiencia real, concluyendo sobre la importancia de un modelo estándar en la evaluación de contratistas que cuenten con experiencia para la labor a la que se presentan; es así que Zambrano & Vidal (2018) añaden que es importante considerar criterios como la calidad, el costo, la capacidad técnica y el cumplimiento normativo.

En consecuencia, debido a la discusión realizada, se ha demostrado que el modelo Deep Learning tiene una influencia significativa y positiva en la Experiencia real de los contratistas en el sector minero. Por tanto el Modelo Deep Learning exhibe un desempeño excepcional al aproximarse de manera significativa a las decisiones tomadas por el comité evaluador; este hallazgo es de gran importancia, ya que resalta la efectividad y precisión

del modelo Deep Learning en el análisis de los servicios relacionados para la dimensión de la experiencia real de los contratistas, perteneciente al sistema de selección de contratistas del sector minero.

7.2. Aporte científico

El aporte científico producto de la tesis doctoral Modelo Deep Learning en el sistema de selección de contratistas en el sector minero, Tacna 2023, ha conseguido un aporte importante al conocimiento y campo de acción del estudio, partiendo de la evidencia de los resultados descriptivos e inferenciales procesados e interpretados, destacando los siguientes aspectos.

Contribución al proceso de selección de contratistas en la industria minera, agilizando la evaluación de expedientes por el comité correspondiente, mediante la incorporación del Modelo Deep Learning como una herramienta de apoyo en una etapa previa o temprana al proceso de evaluación, que posteriormente será corroborado por el comité evaluador. Basado en los resultados obtenidos se demostró que el modelo logra aproximarse de manera consistente a las evaluaciones realizadas por el comité en las diferentes dimensiones e indicadores analizados, como la cartera de clientes, la evaluación crediticia y la experiencia real de los contratistas.

Eficiencia y precisión en la evaluación de expedientes, mediante la aplicación del Modelo Deep Learning se ha demostrado la alta eficacia y precisión al analizar la información contenida en los expedientes de los contratistas, ello se refleja en los resultados de la regresión lineal simple, que indica que el modelo explica la variabilidad de las variables al igual que los valores de los coeficientes estandarizados que una fuerte relación positiva entre el modelo Deep Learning y las variables analizadas, lo que resalta su capacidad para capturar patrones y características importantes que elevan su eficacia al momento de dar resultados similares a los humanos.

Contribución a la mejora continua del proceso de selección de contratistas, a través de los resultados obtenidos se brinda información relevante para la toma de

decisiones en el proceso de selección de contratistas en la industria minera, pues que se da un análisis más ágil y preciso de los expedientes gracias al modelo Deep Learning, que debe ser utilizado como una herramienta complementaria al trabajo del comité evaluador, mejorando la eficiencia y efectividad del proceso de selección y, a su vez, optimizando el uso de recursos y tiempo.

Teóricamente el aporte de la tesis se da en la generalización a otras empresa mineras e industrias que tengan entre sus procesos críticos la contratación de servicios especializados; aunque el estudio se centra en la industria minera en Tacna, los resultados obtenidos tienen el potencial de generalizarse a otras industrias con procesos de selección de contratistas similares, siendo el Modelo Deep Learning una opción tecnológica altamente viable y aplicarse en diferentes contextos para agilizar y mejorar la toma de decisiones en la evaluación de proveedores y contratistas, lo que tendría un impacto positivo en la eficiencia de diversos sectores económicos de las organizaciones.

También se aporta a la literatura sobre el avance y uso de técnicas de inteligencia artificial en el ámbito minero, habiendo utilizado en la tesis tres algoritmos de clasificación que fueron por redes neuronales artificiales multiclase, por algoritmos de recomendación y por el algoritmo transformer, siendo este último el que mayor precisión y fiabilidad brindo, demostrando viabilidad y utilidad en la aplicación de esta tecnología al proceso de selección de contratistas, y por tanto se abre una línea de investigación importante que se enfoca en industrias altamente productivas.

Es así como el Modelo Deep Learning aplicado al sistema de selección de contratistas en el sector minero, proporcionó resultados sólidos que respaldan la implementación de la inteligencia artificial (IA) como una herramienta eficaz para mejorar el proceso de selección de contratistas. Además, los hallazgos contribuyen al avance del conocimiento en el uso de técnicas de IA en el ámbito minero con el potencial de ser aplicados en otras industrias para optimizar sus procesos de selección de proveedores y contratistas.

CONCLUSIONES

Primero

Se concluye que existe influencia significativa y positiva (0,996; sig. 0,000) según el estadístico de regresión lineal simple entre el modelo Deep learning y el sistema de selección de contratistas en el sector minero, además el modelo Deep Learning ha demostrado ser capaz de generar resultados cercanos a las evaluaciones realizadas por el comité de la empresa minera, esta consistencia es muy prometedora, ya que indica que el modelo puede identificar patrones y características importantes en los expedientes de los contratistas, permitiendo hacer recomendaciones acertadas.

Segundo

Se concluye que existe influencia significativa y positiva (0,965; sig. 0,000) según el estadístico de regresión lineal simple entre el modelo Deep learning y la cartera de clientes de los contratistas en el sector minero, por tanto la concordancia entre los resultados del modelo y las evaluaciones realizadas a la cartera de clientes de los contratistas, resalta como una evidencia la efectividad y utilidad del modelo Deep Learning en el análisis de la relación comercial con otras empresas en la gestión de la cartera de clientes del sistema de selección de contratistas del sector minero.

Tercero

Se concluye que existe influencia significativa y positiva (0,941; sig. 0,000) según el estadístico de regresión lineal simple entre el modelo Deep learning y la evaluación crediticia de los contratistas en el sector minero, por ello el Modelo Deep Learning muestra un rendimiento sobresaliente al aproximarse significativamente a las decisiones tomadas por el comité evaluador, destacando la efectividad y precisión en el análisis de la salud crediticia en términos de riesgo dentro de la evaluación crediticia del sistema de selección de contratistas del sector minero.

Cuarto

Se concluye que existe influencia significativa y positiva (0,997; sig. 0,000) según el estadístico de regresión lineal simple entre el modelo Deep learning y la experiencia real de los contratistas en el sector minero, siendo el Modelo Deep Learning excepcional al demostrar un alto rendimiento en la evaluación del contratista, resaltándose la efectividad y precisión del modelo en el análisis de los servicios relacionados con su experiencia real en el sistema de selección de contratistas del sector minero, permitiendo mejorar y agilizar los procesos de selección en la industria con eficiencia y calidad en las decisiones tomadas para la adquisición de servicios de contratistas.

RECOMENDACIONES

Primero

Se recomienda al Superintendente, al funcionario de Tecnologías de la información y el funcionario de Contratos y Servicios de la empresa de Southern Perú, conformar un equipo multidisciplinario que se encargue de desarrollar e implementar una hoja de ruta detallada para la adopción y mejora continua del modelo de Deep Learning, esta hoja de ruta deberá incluir hitos específicos en la validación de la calidad y eficacia del modelo, incorporación de nuevos conjuntos de datos y técnicas de aprendizaje automático que se adapten a los cambios dinámicos en el sector minero, estableciendo un sistema de retroalimentación activa que permita ajustes basados en el rendimiento real y las tendencias emergentes, para asegurar la adaptabilidad y eficacia del modelo en el tiempo, mejorando así la precisión en la selección de contratistas y la capacidad de respuesta de este sector altamente competitivo.

Segundo

Se recomienda al Superintendente y el funcionario de Contratos y Servicios de la empresa de Southern Perú, realizar evaluaciones de sostenibilidad y responsabilidad social de los contratistas, ello implica el desarrollo e implementación de indicadores específicos que midan el impacto ambiental, la gestión de la seguridad laboral y la integración comunitaria de los contratistas, esta ampliación de criterios en el proceso de selección permitirá a la empresa minera optimizar sus decisiones, para seleccionar socios operativos y comerciales que no solo cumplan con los requisitos técnicos y económicos, sino que también compartan sus valores de sostenibilidad y responsabilidad social, contribuyendo así a una minería más ética y sostenible.

Tercero

Se recomienda al comité evaluador de contratistas de Southern Perú, posterior a la implementación del modelo Deep Learning, llevar a cabo un meticuloso proceso de validación de seis meses de los resultados generados por el modelo, centrándose en su integración como herramienta decisiva en la selección de contratistas, este proceso debe incluir revisiones periódicas, comparaciones analíticas, y la recolección de

retroalimentación detallada, destinadas a calibrar y perfeccionar el modelo continuamente, además es esencial que este periodo de evaluación se complemente con sesiones de capacitación dirigidas al comité evaluador, para mejorar su habilidad en la interpretación y aplicabilidad las recomendaciones producto del modelo Deep learning de manera efectiva.

Cuarto

Se recomienda al Superintendente, al funcionario de Tecnologías de la información y el funcionario de Contratos y Servicios de la empresa de Southern Perú, adoptar tecnologías avanzadas en la recopilación y gestión de datos, como Internet de las Cosas (IoT) y blockchain, asegurando la integridad, transparencia y actualización de los datos de desempeño de los contratistas, siendo relevante desarrollar y emplear un conjunto amplio de métricas de rendimiento que evalúen la eficacia del modelo Deep Learning, tanto en la precisión de recomendaciones así como en el impacto de la eficiencia operativa, reducción de riesgos y promoción de la sostenibilidad, para garantizar que el modelo de Deep Learning sea una herramienta dinámica y efectiva en la toma de decisiones estratégicas de selección de contratistas.

FUENTES DE INFORMACIÓN

- A., T., Barton, R., & Chuke-Okafor, C. (2008). Applying lean six sigma in a small engineering company a model for change. *Journal of Manufacturing Technology Management*, 129.
- Abad Moran, J., Vera Aguirre, J., & Cabanilla Sanchez, B. (2019). Aplicación de Lean Seis Sigma para reducir el tiempo en la elaboración de contratos en una institución de Educación Superior. *LACCEI International Multi-Conference for Engineering, Education, and Technology*, 26.
- Águeda Barrero, A. (2010). *Guía del PMBOK® vs PRINCE2™*. Madrid: Apmg International.
- Alvarez Pedroza, A. (2021). *Comentarios al reglamento y ley de contrataciones del Estado*. Lima: Instituto Pacifico S.A.C.
- Andrew, T., & Barton, R. (2011). Using the Quick Scan Audit Methodology (QSAM) as a precursor towards successful Lean Six Sigma implementation. *International Journal of Lean Six Sigma*, 54.
- Anglo American. (30 de 1 de 2023). <https://socialway.angloamerican.com/es-es/toolkit/impact-and-risk-prevention-and-management/contractor-social-management/introduction/about-contractor-social-management>. Obtenido de Acerca de la gestión social de contratistas: <https://socialway.angloamerican.com/es-es/toolkit/impact-and-risk-prevention-and-management/contractor-social-management/introduction/about-contractor-social-management>
- Arenas, V. L. (2017). La ejecución contractual en la Gobernatura Regional del Cusco. *Universidad Andina del Cusco*, 123.

- Aven, T. (2012). *The risk concept—historical and recent development trends. Reliability Engineering & System Safety*, 99, 33-44.
<https://doi.org/10.1016/j.res.2011.11.006>
- Barcelli, G., Henrich, M., & León, J. (2007). Un método de mejora de proceso para pymes en países en desarrollo. *Ingeniería Industrial*, (25), 33-49.
- Babbie, E. R. (2018). *The practice of social research* (15th ed.). Cengage Learning.
- Benavides Fernández, Y., & Muñoz Alegre, J. A. (2019). *Modelo de gestión para evaluación de empresas contratistas del sector minero en el Perú*. Universidad de Piura. <https://pirhua.udep.edu.pe/handle/11042/3846>
- Bengio, Y. (2009). *Learning deep architectures for AI. Foundations and Trends® in Machine Learning*, 2(1), 1-127. <https://doi.org/10.1561/22000000006>
- Buduma, N. (2016). *Fundamentals of deep learning: Designing next-generation machine intelligence algorithms*. . Washington: O'Reilly Media, Inc.
- Casanova Vise, F. E., & Diaz Mendoza, R. F. (2020). *Procedimiento de selección de subcontratistas en proyectos de carreteras en el Perú mediante el análisis multicriterio*. Universidad Peruana de Ciencias Aplicadas (UPC).
<https://repositorioacademico.upc.edu.pe/handle/10757/652274>
- Centro de Especialización en Gestión Pública . (22 de Febrero de 2021). *¿Qué es el OSCE?* Obtenido de CEGEP PERU: <https://cegepperu.edu.pe/2021/02/22/que-es-el-osce/>
- Chafloque Ballena, J. M. (2021). Proceso de contrataciones en provias descentralizado y su relación con el desarrollo, Periodo 2018 - 2019. *Centro de Altos Estudios Nacionales*, 109.
- Chakravorty, S. S. (2009). Six Sigma Programs: An Implementation Model. *International Journal of Production Economics*, 16.

- Chiavenato, I. (2019). *Administración de recursos Humanos* (Vol. 10ma). Mexico: McGraw Hill.
- Choque Percca, A. A., Quiñones Vélez, P., Salas Rodríguez, D., & Salvatierra Manchego, V. (2016). Propuesta para la mejora del servicio de Outsourcing de atención presencial al cliente en una empresa de seguros. *Universidad Peruana de Ciencias Aplicadas (UPC)*, 125.
- Cilotta, P. (31 de 05 de 2018). *La situación del "Contract Management" en España*. Obtenido de IACCM: <https://pmi-mad.org/images/2018/RMensuales/mayo/IACCM-Presentacion-en-PMI-Madrid-Pablo-Cilotta-31-Mayo-2018.pdf>
- Creswell, J. W., & Creswell, J. D. (2018). *Research design: Qualitative, quantitative, and mixed methods approaches (5th ed.)*. SAGE Publications.
- Donoho, D. (2017). *50 years of Data Science*. *Journal of Computational and Graphical Statistics*, 26(4), 745-766. <https://doi.org/10.1080/10618600.2017.1384734>
- Floridi, L., & Cowls, J. (2019). *A unified framework of five principles for AI in society*. Harvard Data Science Review.
- Fraenkel, J. R., Wallen, N. E., & Hyun, H. H. (2022). *How to design and evaluate research in education (10th ed.)*. McGraw-Hill.
- Ghobadian, A., Gallear, D., & Hopkins, M. (2007). *TQM and CSR nexus*. United Kingdom: International Journal of Quality & Reliability Management.
- Gido, J., & Clements, J. (2014). *Administración exitosa de Proyectos* (5ta ed.). Mexico: Cengage Learning.
- Gnanaraj, S. M., Devadasan, S., Muruges, R., & Sreenivasa, C. (2011). Sensitisation of SMEs towards the implementation of Lean Six Sigma – an initialisation in a cylinder frames manufacturing Indian SME. *Production Planning & Control*, 18.

- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning (Vol. 1)*. Massachusetts: MIT Press.
- Gutierrez Pulido Roman de la Vara Salazar, H. (2013). *Control estadístico de calidad y seis sigma*. Mexico D.F.: McGraw-Hill.
- Heizer, J., & Render, B. (2019). *Principios de Administración de Operaciones (7ma ed.)*. Mexico: Pearson Education.
- Herrera, R., & Fontalvo, T. (2011). *Seis Sigma: Métodos Estadísticos y Sus Aplicaciones*. Edición Electrónica Gratuita.
- Hernández-Sampieri, R., & Mendoza, C. (2018). *Metodología de la investigación (6th ed.)*. McGraw-Hill.
- Hinton, G., Osindero, S., & Teh, Y. W. (2006). *A fast learning algorithm for deep belief nets*. *Neural Computation*, 18(7), 1527-1554. <https://doi.org/10.1162/neco.2006.18.7.1527>
- Imai, M. (1989). *Kaizen: La Clave de la Ventaja Competitiva Japonesa (Décimo tercera ed.)*. México: Compañía Editorial Continental.
- J. Carreño & R. Sanchez (2019) *Evaluación de contratistas en la industria minera peruana: un enfoque basado en el índice de capacidad financiera e inteligencia artificial*, Universidad del Pacifico.
- J. Zambrano & R. Vidal (2018) *Evaluación de proveedores en la industria minera peruana: Un enfoque de multicriterio utilizando tecnología de datos*, Universidad de Lima.
- Keeney, R. L. (1982). *Decision analysis: An overview*. *Operations Research*, 30(5), 803-838. <https://doi.org/10.1287/opre.30.5.803>
- García, G., Ferro, M., & Lautaro, A. (2021). *An adaptive fuzzy approach based on Artificial Intelligence for the balanced selection of risk allocation in construction projects.. International Journal of Project Management*.

- Knowles, G., Whicker, L., Femat, J. H., & Canales, F. D. (2007). A conceptual model for the application of Six Sigma methodologies to supply chain improvement. *International Journal of Logistics Research and applications*, 65.
- Kumar, M., Antony, J., & Tiwari, M. K. (2011). Six Sigma implementation framework for SMEs—a roadmap to manage and sustain the change. *International Journal of Production Research* , 49.
- Lahdhiri, M., Babay, A., & Jmali, M. (2022). *Multi-criteria decision making using hybrid methods for supplier selection in the clothing industry*. *Fibres & Textiles in Eastern Europe*, 30(2), 23–34. <https://doi.org/10.2478/ftce-2022-0004>
- Lewin, K. (1951). *Field theory in social science: Selected theoretical papers*. New York: Harper.
- Ley N. 30225. (2019). *Ley de Contrataciones del Estado*. Lima: Diario Oficial "El Peruano".
- Ley N° 29245. (19 de 08 de 2008). *Ley que regula los servicios de tercerizacion*. Lima: Diario Oficial "El Peruano".
- Ley N° 29783. (2011). *Ley de seguridad y salud en el trabajo*. Lima: Diaro Oficial "EL PERUANO".
- Lopez Guerrero, A., Hernandez Gomez, J. A., Velazquez Victorica, K. I., & Olivares Fong, L. D. (2019). *Seis Sigma como estrategia competitiva: principales aplicaciones, sectores de implementación y factores críticos para el éxito (FCE)*. Mexico D.F.: Universidad Autonoma de Baja California.
- Lopez, P. (2016). *Herramientas para la mejora de la calidad: Métodos para la mejora continua y la solución de problemas*. Madrid: Fundacion Confemetal.
- MacPepple, K. (2020). *Principles of Contract Management*. Londres: Nielsen UK ISBN Store.

- Maqsoom, A., Bajwa, S., & Zahoor, H. (2019). Optimizing contractor's selection and bid evaluation process in construction industry: Client's perspective. 445-458. doi:doi:10.30827/rconst.v18n3.7248451
- Maqsoom, A., Bajwa, S., Zahoor, H., Deakin University, Dawood, M., (2019). *Optimizing contractor's selection and bid evaluation process in construction industry: Client's perspective*. Revista de La Construcción, 18(3), 445-458. <https://doi.org/10.7764/RDLC.18.3.445>
- Ministerio de Justicia del Perú . (2019). *Texto Unico Ordenado de la Ley 30225 Ley de Contrataciones del Estado*. Perú: El Peruano.
- Miranda , F., Chamorro , A., & Rubio , S. (2007). *Introduccion a la Gestion de la Calidad*. Madrid: Delta Publicaciones Universitarias. Recuperado el 18 de agosto de 2020, de <https://books.google.com.pe/books?id=KYSMQQyQAbYC&lpg=PA76&dq=7%20herramientas%20de%20calidad%20diagrama%20de%20flujo&pg=PP1#v=onepage&q=7%20herramientas%20de%20calidad%20diagrama%20de%20flujo&f=false>
- Moron Urbina, J. C. (2016). *La contratación estatal: Análisis de las diversas formas y técnicas contractuales que utiliza el Estado*. Lima: Gaceta Juridica.
- Naghizadeh Vardin, A., Ansari, R., Khalilzadeh, M., Antucheviciene, J., & Bausys, R. (2021). *An integrated decision support model based on bwm and fuzzy-vikor techniques for contractor selection in construction projects*. Sustainability, 13(12), 6933. <https://doi.org/10.3390/su13126933>
- Navarro, E., Gisbert , V., & Pérez, A. (2017). Metodología e implementación de Six Sigma. *3C Empresa: investigación y pensamiento crítico*, 73-80.

- Nieto-Morote, A., & Ruz-Vila, F. (2022). *A fuzzy multi-criteria decision-making model for construction contractor prequalification. Automation in Construction, 25*, 8–19.
- Nuñez Salas, M., & Talavera Cano, A. (2021). *Contrataciones con el Estado: Perspectivas desde la práctica del Derecho*. Lima: Fondo Editorial Universidad del Pacífico Perú.
- Ortiz, K. L. (2018). *Metodología ágil para la gestión de proyectos*. La paz: Epistemus.
- Oyewole B., (2018). *Framework for evaluating SMEs in pre-qualification schemes by the oil, gas and mining sector, Central Africa*. <https://unctad.org/node/5320>
- Palffy, G. (s.f.). *How Business Works*. DK Publishing. Recuperado el 30 de 1 de 2023
- Pampliega, C. (10 de 3 de 2020). *IA y Project Management: La actual Dirección de Proyectos en las PYMEs*. Obtenido de Capterra: <https://www.capterra.es/blog/1352/ia-y-project-management-i-la-actual-direccion-de-proyectos-en-las-pymes>
- Performance Indicator*. (s.f.). Recuperado el 30 de 1 de 2023, de Wikipedia: The Free Encyclopedia: http://en.wikipedia.org/wiki/Performance_indicator
- Popper, K. (2008). *The logic of scientific discovery*. Routledge
- Proaño, D., Gisbert, V., & Pérez, E. (2017). Metodología para elaborar un plan de mejora continua. *3C Empresa: Investigación y Pensamiento Crítico*, 50 – 56.
- Project Managment Institute. (2021). *Guía de los fundamentos para la dirección de proyectos*. Pensilvania: Project Management Institute, Inc.
- PROMOVE Consultoria e Formacion SLNE. (2012). *Cómo elaborar el análisis DAFO*. Santiago de Compostela: BIC GALICIA.
- Pryke, S. (2012). *Managing networks in project-based organisations*. John Wiley & Sons.

- RDYGAM S.R.L. (2019). *Manual de procedimientos internos y servicios*. Ilo: RYDGAM SRL.
- Redacción Gestión. (24 de 8 de 2022). *Qué es exactamente la tercerización laboral*. Obtenido de Diario Gestión : <https://gestion.pe/economia/que-es-exactamente-la-tercerizacion-laboral-peru-nnda-nnlt-noticia/>
- Rodríguez, J., Gómez, M., & López, R. (2020). *Modelo Deep learning en el procedimiento de selección de subcontratistas en proyectos de carreteras en el Perú 2019*. Revista de Construcción y Obras Públicas, 25(2), 123-138.
- Rocchio, J. J. (1971). *Relevance feedback in information retrieval. The SMART retrieval system: Experiments in automatic document processing*.
- Rogers, E. M. (2003). *Diffusion of innovations*. Nueva York: Free Press.
- Rojas, J., & Rojas, M. (2018). Selección de contratistas en la industria minera de Chile: una aproximación desde la teoría de juegos. 111-120. doi:doi:10.5565/rev_ing.ind.v30n2.2018006
- Russell, S. J., & Norvig, P. (2016). *Artificial intelligence: A modern approach*. Malaysia; Pearson Education Limited.
- Sagástegui Plate, D. E. (2020). Calidad en las Empresas en el Sector Minería del Perú.
- Sanchez, C. (2020). *Normas APA (7ma edición)* (Vol. 7ma edición). Madrid: Universidad Complutense de Madrid.
- Schneider, B. (2007). *Outsourcing. La herramienta de gestión que revoluciona*. Lima: Editorial Norma.
- Spencer, H. (2009). *An Autobiography*. Nueva York: Cornell University Library.
- Strickland III, A., Peteraf, M., Gamble, J., & Thompson, A. (2012). *Administración estratégica teoría y casos* (18va ed.). Nueva York: McGraw-Hill.

- Taylan, O., Kabli, M. R., Porcel, C., & Herrera-Viedma, E. (2018). *Contractor Selection for Construction Projects Using Consensus Tools and Big Data*. *International Journal of Fuzzy Systems*, 20(4), 1267–1281. <https://doi.org/10.1007/s40815-017-0312-3>
- Terrazas, R. (2011). Planificación y programación de operaciones. *Redalyc.org*, 27.
- Tiwana, A. (2010). *Knowledge Management Toolkit, The: Practical Techniques for Building a Knowledge Management System*. Atlanta: Prentice Hall PTR.
- Walker, A. (2007). *Project management in construction*. John Wiley & Sons.
- Wang, E., & Caldwell, B. (2002). *An empirical study of usability testing: Heuristic evaluation vs. User testing*. *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*, 46(8), 774–778. <https://doi.org/10.1177/154193120204600802>
- World Commerce And Contracting Association | WorldCC. (n.d.). <https://www.worldcc.com/>
- Zavadskas, E. K., Turskis, Z., & Tamošaitienė, J. (2010). *Contractor selection of construction in a competitive environment*. *Journal of Business Economics and Management*, 11(2), 227-251. <https://doi.org/10.3846/jbem.2010.11>

ARTÍCULO CIENTÍFICO

1. TÍTULO

Modelo Deep Learning en el sistema de selección de contratistas en el sector minero, Tacna 2023

AUTOR: Dr. Juan Carlos Jimenez Flores

INSTITUCIÓN: Universidad Alas Peruanas

2. RESUMEN

La industria minera forma parte de uno de los sectores productivos de mayor importancia a nivel mundial debido a su papel en la provisión de materias primas para diversos sectores industriales, en este sentido la elección de contratistas para proyectos mineros y servicios puede ser un proceso complejo y costoso para las empresas mineras, sin embargo con el auge de la inteligencia artificial en distintos ámbitos productivos a nivel global, se ha intensificado el uso de modelos Deep Learning para tomar decisiones informadas y objetivas, en ese sentido el propósito del estudio fue determinar la influencia del modelo Deep learning en el sistema de selección de contratistas en el sector minero, Tacna 2023. Metodológicamente fue una investigación de enfoque cuantitativo de tipo aplicada, de nivel descriptivo y explicativo, empleando el método hipotético deductivo, de diseño experimental, longitudinal y preexperimental, con una población y muestra conformada por 213 expedientes de contratistas en el sector minero, siendo la técnica utilizada el análisis documental y el instrumento la ficha de recolección de datos. Sobre el resultado obtenido del estadístico regresión lineal simple, se obtuvo 0.996 y una sig. de 0.000, aceptando la hipótesis alternativa (H_a) y rechazando la hipótesis nula (H_0). Por tanto se concluye que el modelo Deep Learning ha demostrado ser capaz de generar resultados cercanos a las evaluaciones realizadas por el comité de la empresa minera, esta consistencia es muy prometedora, ya que indica que el modelo puede identificar patrones y características importantes en los expedientes de los contratistas, permitiendo hacer recomendaciones acertadas.

PALABRAS CLAVE: Deep Learning, selection system, contractors, mining

3. INTRODUCCIÓN

La industria minera es reconocida a nivel mundial como uno de los sectores más importantes, ya que proporciona materia prima para diversos sectores industriales. Sin embargo, la selección de contratistas para llevar a cabo proyectos mineros puede ser un proceso complejo y costoso para las empresas mineras. En este contexto, el uso de modelos de aprendizaje profundo podría ser una solución prometedora para mejorar el proceso de selección de contratistas, ya que permite analizar grandes volúmenes de datos históricos y en tiempo real para identificar patrones y tomar decisiones informadas (Maqsoom et al., 2019).

Para contextualizar el problema y justificar la necesidad de una solución eficiente, es esencial contar con cifras relevantes sobre el sector minero a nivel global. Según el informe del Consejo Internacional de Minería y Metales (ICMM) de 2021, la producción minera mundial en 2020 alcanzó los 18.1 billones de toneladas métricas, con un valor de mercado de 802 mil millones de dólares. Además, se estima que la industria minera emplea aproximadamente a 11 millones de personas en todo el mundo. Estas cifras pueden variar significativamente según las regiones, lo que destaca la importancia de recopilar y analizar datos específicos para cada ubicación.

En respuesta a los desafíos que enfrenta la selección de contratistas, diversos investigadores han propuesto metodologías para mejorar el proceso. Por ejemplo, Maqsoom et al. (2019) analizaron el proceso de selección de contratistas y la evaluación de ofertas en la industria de construcción minera desde la perspectiva del cliente. Destacaron la necesidad de un enfoque más completo y objetivo en la toma de decisiones y propusieron un marco de toma de decisiones de criterios múltiples (MCDM) para ayudar a los clientes a seleccionar contratistas con mayor probabilidad de entregar proyectos a tiempo, dentro del presupuesto y cumpliendo con los estándares de calidad.

En América Latina, Rojas, J. & Rojas, M. (2018) analizaron la selección de contratistas en la industria minera chilena desde la perspectiva de la teoría de juegos. Argumentaron que el proceso actual es ineficiente y requiere un enfoque más estratégico. Su modelo de

teoría de juegos propuesto tiene como objetivo ayudar a las empresas mineras a seleccionar contratistas con el costo más bajo.

Del mismo modo, Sagástegui Plate, D. E. et al. (2021) probaron un modelo de gestión para evaluar empresas contratistas en el sector minero peruano. Su enfoque se centró en mejorar los indicadores operativos y la calidad del servicio de los principales proveedores de empresas mineras. Además, destacaron la importancia de una cultura de calidad en la industria minera peruana para aprovechar los beneficios del sistema de gestión de calidad y fortalecer las operaciones mineras.

A nivel local, Southern es una empresa minera con operaciones en Tacna, Ilo, Moquegua, y ha identificado la necesidad de una gestión eficiente de contratistas para garantizar la calidad de los trabajos y la seguridad de los trabajadores. A medida que la empresa experimenta un crecimiento constante, contar con un proceso de selección de contratistas efectivo y confiable se vuelve cada vez más crucial. Los métodos de evaluación actuales a menudo dependen de la intuición humana y pueden ser subjetivos e inconsistentes, lo que genera riesgos para la calidad de los trabajos y la seguridad de los trabajadores al contratar empresas o personas no calificadas para realizar las tareas requeridas de manera segura y eficiente.

Entre los posibles síntomas de no contar con un sistema de selección de contratistas alineado a las necesidades de la empresa se encuentran la calidad deficiente de los trabajos realizados por los contratistas, altos índices de accidentes y lesiones laborales, y el incumplimiento de plazos y presupuestos en base a una inadecuada selección de contratistas para el proceso de licitación.

Entre las posibles causas que originan el problema se identifican la falta de criterios claros y estandarizados de evaluación entre las unidades operativas de la empresa, la ausencia de procesos estructurados y la falta de recursos y personal capacitado para llevar a cabo una evaluación exhaustiva de los contratistas.

De las consecuencias producto del problema expuesto se tiene el riesgo para la seguridad de los trabajadores, costos adicionales debido a trabajos de baja calidad y retraso en los proyectos, lo que afectará la planificación y los plazos establecidos.

En este contexto, la aplicación de tecnologías como el modelo de Deep Learning podría ser una solución prometedora en el proceso de selección de contratistas en Southern. El Deep Learning es una rama de la inteligencia artificial que utiliza redes neuronales profundas para el procesamiento y análisis de datos complejos. Implementar un modelo de Deep Learning en el sistema de selección de contratistas permitiría utilizar algoritmos avanzados para evaluar de manera objetiva y precisa los antecedentes, habilidades, experiencia de los candidatos y el cumplimiento de requisitos legales y normativos, entre otros, minimizando la influencia de sesgos subjetivos y aumentando la consistencia en la toma de decisiones (Maqsoom et al., 2019).

Por tanto se plantea la pregunta ¿Cuál será la influencia del modelo Deep learning en el sistema de selección de contratistas en el sector minero, Tacna 2023?.

También se plantea el objetivo del estudio, Determinar la influencia del modelo Deep learning en el sistema de selección de contratistas en el sector minero, Tacna 2023.

Finalmente se plantea la hipótesis, Existe influencia del modelo Deep learning en el sistema de selección de contratistas en el sector minero, Tacna 2023.

4. MATERIALES Y MÉTODOS

La investigación fue de enfoque cuantitativo y de tipo aplicada, en el nivel descriptivo y explicativo. El método empleado fue el hipotético deductivo. Del diseño de la investigación fue experimental, longitudinal y preexperimental, debido a que se estableció la relación causa – efecto entre variables (Creswell & Creswell, 2018), (Fraenkel et al., 2022), (Hernández-Sampieri & Mendoza, 2018).

La población estuvo compuesta por 213 expedientes de contratistas que se extraerán de las unidades de logística de Tacna, Ilo y Moquegua. La técnica empleada fue el análisis documental, y el instrumento la ficha de recolección de datos (Popper, 2008).

Al ser un estudio de diseño experimental la medición para la variable dependiente “Sistema de selección de contratistas” estuvo compuesta por una ficha de evaluación para el expediente del contratista que constó de:

- a) Dimensión cartera de clientes
Indicadores: Relación mercantil con otras empresas
- b) Dimensión evaluación crediticia
Indicadores: Salud crediticia a nivel de riesgo
- c) Dimensión experiencia real
Indicador: Servicios relacionados

Y para el correcto procesamiento y análisis de los datos se diseñó la ficha de recolección de datos, eligiendo los niveles o modalidades de manipulación de las variables. Realizando un seguimiento a la población en torno a la recolección de las fichas proveniente de las unidades logísticas de la empresa ubicados en los departamentos de Tacna Ilo y Moquegua. Siendo los datos procesados en SPSS 27, posteriormente se realizaron los análisis descriptivos e inferenciales Babbie (2018).

5. RESULTADOS

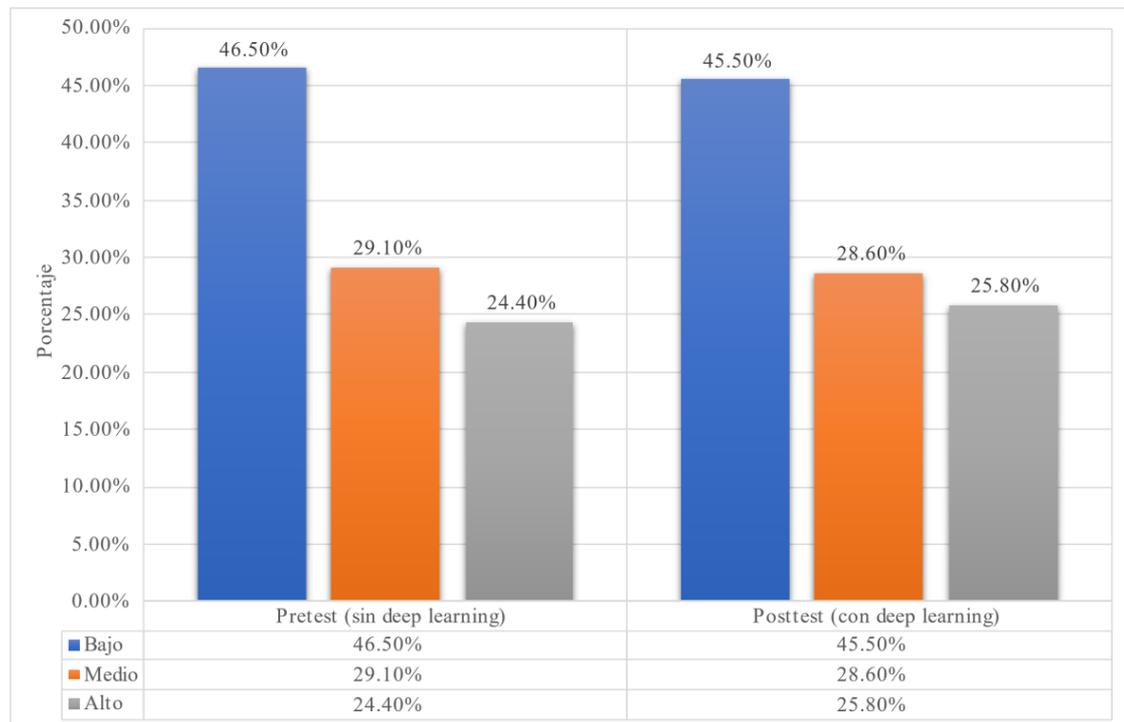
En concordancia por el propósito del estudio se evalúa las frecuencias del sistema de selección de contratistas.

Tabla 1
Frecuencias de DI. Cartera de clientes - i. Relación mercantil con otras empresas

Nivel	Pretest (sin deep learning)		Posttest (con deep learning)	
	fr.	%	fr.	%
Bajo	99	46.50%	97	45.50%
Medio	62	29.10%	61	28.60%
Alto	52	24.40%	55	25.80%
Total	213	100.00%	213	100.00%

Figura 1

Frecuencias en % de D1. Cartera de clientes - i. Relación mercantil con otras empresas



Los resultados obtenidos tras analizar la distribución de los niveles del indicador "i. Relación mercantil con otras empresas" de la dimensión "D1. Cartera de clientes" muestran ligeras variaciones entre el pretest y el posttest; estas observaciones sugieren que la incorporación del Modelo Deep Learning en la evaluación del indicador "i. Relación mercantil con otras empresas" produce resultados prácticamente similares a las evaluaciones de expedientes realizados por el comité de la empresa minera.

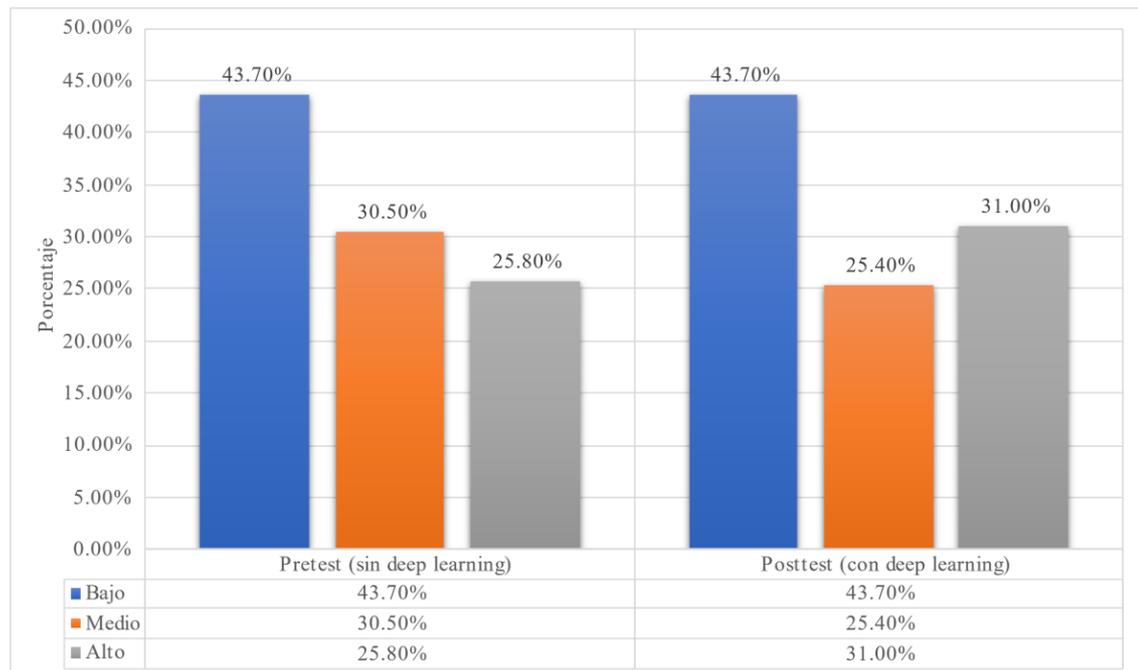
Tabla 2

Frecuencias de D2. Evaluación crediticia - i. Salud crediticia a nivel de riesgo

Nivel	Pretest (sin deep learning)		Posttest (con deep learning)	
	fr.	%	fr.	%
Bajo	93	43.70%	93	43.70%
Medio	65	30.50%	54	25.40%
Alto	55	25.80%	66	31.00%
Total	213	100.00%	213	100.00%

Figura 2

Frecuencias en % de D2. Evaluación crediticia - i. Salud crediticia a nivel de riesgo

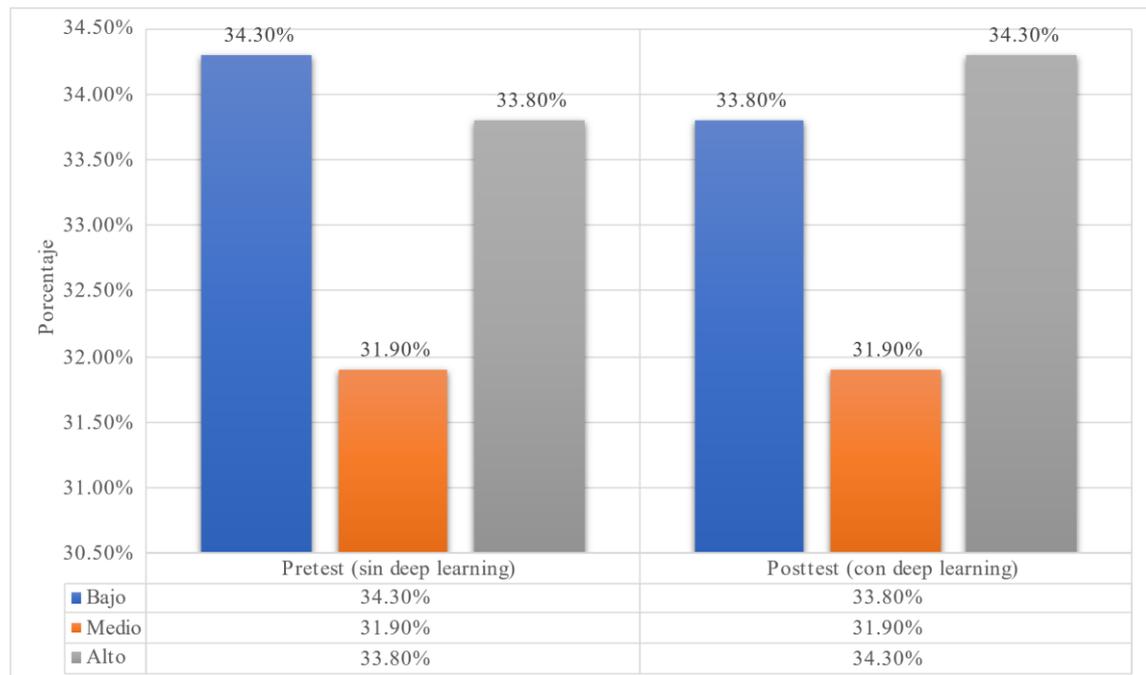


Los resultados obtenidos del análisis de la distribución de los niveles del indicador "i. Salud crediticia a nivel de riesgo" de la dimensión "D2. Evaluación crediticia" muestran ligeras variaciones entre el pretest y el posttest; estos hallazgos sugieren que la aplicación del Modelo Deep Learning en el indicador "i. Salud crediticia a nivel de riesgo" arroja resultados prácticamente similares a las evaluaciones realizadas por el comité de la empresa minera en relación con los expedientes de los contratistas evaluados por dicho comité.

Tabla 3

Frecuencias de D3. Experiencia real - i. Servicios relacionados

Nivel	Pretest (sin deep learning)		Posttest (con deep learning)	
	fr.	%	fr.	%
Bajo	73	34.30%	72	33.80%
Medio	68	31.90%	68	31.90%
Alto	72	33.80%	73	34.30%
Total	213	100.00%	213	100.00%

Figura 3*Frecuencias en % de D3. Experiencia real - i. Servicios relacionados*

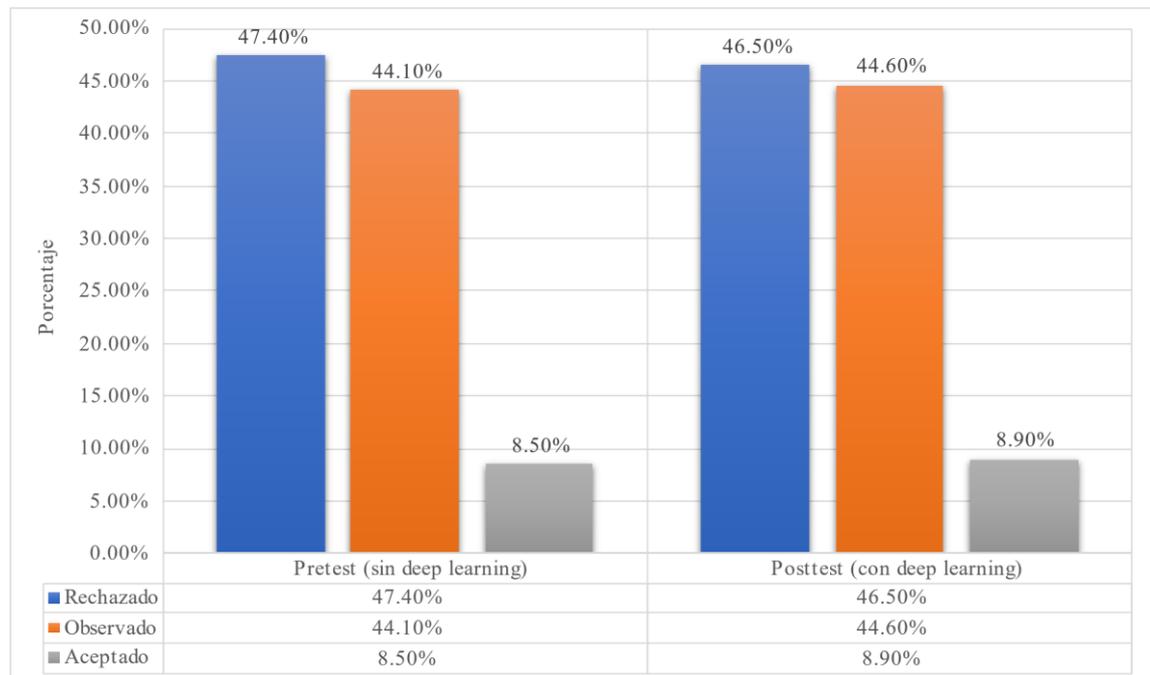
Los resultados obtenidos del análisis de la distribución de los niveles del indicador "i. Servicios relacionados" en la dimensión "D3. Experiencia real" revelan ligeras variaciones entre el pretest y el posttest, estos hallazgos sugieren que la aplicación del Modelo Deep Learning en el indicador "i. Servicios relacionados" arroja resultados prácticamente similares a las evaluaciones realizadas por el comité de la empresa minera en relación con los expedientes de los contratistas.

Tabla 4*Frecuencias del Sistema de selección de contratistas*

Nivel	Pretest (sin deep learning)		Posttest (con deep learning)	
	fr.	%	fr.	%
Rechazado	101	47.40%	99	46.50%
Observado	94	44.10%	95	44.60%
Aceptado	18	8.50%	19	8.90%
Total	213	100.00%	213	100.00%

Figura 4

Frecuencias en % del Sistema de selección de contratistas



El análisis de la tabla revela la distribución de las decisiones del comité sobre los expedientes de los contratistas antes y después de la implementación del modelo Deep Learning, en donde se observa que las proporciones de los expedientes rechazados, observados y aceptados apenas varían entre el pretest y el posttest; esto sugiere que la incorporación del modelo Deep Learning en el sistema de selección de contratistas no ha generado cambios drásticos en las decisiones tomadas por el comité evaluador.

Finalmente sobre los resultados inferenciales para demostrar el propósito planteado se comprueba la hipótesis:

Prueba de hipótesis general

Ho. No existe influencia del modelo Deep learning en el sistema de selección de contratistas en el sector minero, Tacna 2023

Ha. Existe influencia del modelo Deep learning en el sistema de selección de contratistas en el sector minero, Tacna 2023

Tabla 5
Coefficientes^a para el Sistema de selección de contratistas

Modelo	Coeficientes no estandarizados		Coeficientes estandarizados		
	B	Desv. Error	Beta	t	Sig.
(Constante)	0.404	0.156	-	2.586	0.010
Sistema de selección de contratistas (Con Deep Learning)	0.996	0.003	0.999	359.832	0.000

Nota. a. Variable dependiente: Sistema de selección de contratistas (Sin Deep Learning)

En la tabla de coeficientes, se observa que el coeficiente B para "Sistema de selección de contratistas (Con Deep Learning)" es de 0.996. Esto sugiere que hay una fuerte relación positiva entre el modelo Deep Learning y el sistema de selección de contratistas. Y el valor p (0.000) es menor que el nivel de significancia estándar de 0.05, lo que indica que el coeficiente es estadísticamente significativo, aceptando la hipótesis alternativa (Ha) y rechazando la hipótesis nula (Ho).

Prueba de hipótesis específica 1

Ho. No existe influencia del modelo Deep learning en la cartera de clientes de los contratistas en el sector minero, Tacna 2023

Ha. Existe influencia del modelo Deep learning en la cartera de clientes de los contratistas en el sector minero, Tacna 2023

Tabla 6
Coefficientes^a para la Cartera de clientes

Modelo	Coeficientes no estandarizados		Coeficientes estandarizados		
	B	Desv. Error	Beta	t	Sig.
(Constante)	0.045	0.042	-	1.06	0.044
D1. Cartera de clientes (Con Deep Learning)	0.965	0.007	0.994	133.208	0.000

Nota. a. Variable dependiente: D1. Cartera de clientes (Sin Deep Learning)

En la tabla de coeficientes, se observa que el coeficiente B para "D1. Cartera de clientes (Con Deep Learning)" es de 0.965. Esto sugiere que hay una fuerte relación

positiva entre el modelo Deep Learning y la cartera de clientes de los contratistas en el sector minero. Y el valor p (0.000) es menor que el nivel de significancia estándar de 0.05, lo que indica que el coeficiente es estadísticamente significativo, aceptando la hipótesis alternativa (Ha) y rechazando la hipótesis nula (Ho).

Prueba de hipótesis específica 2

Ho. No existe influencia del modelo Deep learning en la evaluación crediticia de los contratistas en el sector minero, Tacna 2023

Ha. Existe influencia del modelo Deep learning en la evaluación crediticia de los contratistas en el sector minero, Tacna 2023

Tabla 7
Coeficientes ^a para la Evaluación crediticia

Modelo	Coeficientes no estandarizados		Coeficientes estandarizados		
	B	Desv. Error	Beta	t	Sig.
(Constante)	0.094	0.051	-	1.836	0.038
D1. Cartera de clientes (Con Deep Learning)	0.941	0.008	0.992	111.283	0.000

Nota. a. Variable dependiente: D2. Evaluación crediticia (Sin Deep Learning)

En la tabla de coeficientes, se observa que el coeficiente B para "D2. Evaluación crediticia (Con Deep Learning)" es de 0.941. Esto sugiere que hay una fuerte relación positiva entre el modelo Deep Learning y la evaluación crediticia de los contratistas en el sector minero. Y el valor p (0.000) es menor que el nivel de significancia estándar de 0.05, lo que indica que el coeficiente es estadísticamente significativo, aceptando la hipótesis alternativa (Ha) y rechazando la hipótesis nula (Ho).

Prueba de hipótesis específica 3

Ho. No existe influencia del modelo Deep learning en la experiencia real de los contratistas en el sector minero, Tacna 2023

Ha. Existe influencia del modelo Deep learning en la experiencia real de los contratistas en el sector minero, Tacna 2023

Tabla 8
Coefficientes^a para la Experiencia real

Modelo	Coeficientes no estandarizados		Coeficientes estandarizados		
	B	Desv. Error	Beta	t	Sig.
(Constante)	0.17	0.125	-	1.364	0.174
D3. Experiencia real (Con Deep Learning)	0.997	0.003	0.999	380.535	0.000

Nota. a. Variable dependiente: D3. Experiencia real (Sin Deep Learning)

En la tabla de coeficientes, se observa que el coeficiente B para "D3. Experiencia real (Con Deep Learning)" es de 0.997. Esto sugiere que hay una fuerte relación positiva entre el modelo Deep Learning y la experiencia real de los contratistas en el sector minero. Y el valor p (0.000) es menor que el nivel de significancia estándar de 0.05, lo que indica que el coeficiente es estadísticamente significativo, aceptando la hipótesis alternativa (Ha) y rechazando la hipótesis nula (Ho).

6. DISCUSIÓN

Sobre el objetivo general, Determinar la influencia del modelo Deep learning en el sistema de selección de contratistas en el sector minero, Tacna 2023; se determinó según la tabla 12 que el estadístico regresión lineal simple, en sus coeficientes, se observó que el coeficiente B para "Sistema de selección de contratistas (Con Deep Learning)" es de 0.996, demostrando que existe una fuerte relación entre el modelo Deep Learning y el sistema de selección de contratistas, siendo el valor p (0.000) menor al nivel de significancia de 0.05, lo que significa que el coeficiente es estadísticamente significativo. Por tanto, se aceptó la hipótesis alternativa (Ha) y se rechazó la hipótesis nula (Ho), concluyendo que el modelo Deep Learning influye positivamente el proceso de selección de contratistas en este sector.

Estos resultados convergen con lo hallado por Taylan et al. (2018) quienes explicaron como el Deep Learning y Big Data inciden en la selección de contratistas para proyectos de construcción mediante herramientas de consenso, resultando que los algoritmos Deep

learning son útiles al momento de seleccionar contratistas por criterios cuantificables sin intervención humana para los proyectos de construcción; del mismo Kizil & Knights (2020) analizaron la aplicación de la inteligencia artificial en la selección de proveedores en la industria minera, concluyendo que el uso de la inteligencia artificial ha tenido gran influencia en la selección de proveedores mineros.

En consecuencia, debido a la discusión realizada, se ha demostrado que el modelo Deep Learning tiene una influencia significativa y positiva en el sistema de selección de contratistas en el sector minero. Por tanto el modelo Deep Learning ha sido capaz de producir resultados cercanos a las evaluaciones realizadas por el comité de la empresa minera, siendo esta consistencia muy prometedora ya que muestra que el modelo es capaz de capturar patrones y características importantes en los expedientes de los contratistas para realizar recomendaciones acertadas.

Cabe discutir que la aplicación del modelo Deep Learning en el Sistema de selección de contratistas de la empresa minera, no tiene como fin sustituir al comité evaluador de los expedientes, los cuales cuentan con todas las aptitudes y capacidades para desarrollar de la mejor manera su labor, si no por el contrario los resultados del modelo Deep Learning sirven para realizar un pre filtro en la evaluación de los expedientes, considerando el alto índice de rechazados u observados y pocos en el nivel aceptado, agilizando así la labor de evaluación de toma de decisiones del comité, mejorando su eficiencia y efectividad.

7. CONCLUSIONES

Se concluye que existe influencia significativa y positiva (0,996; sig. 0,000) según el estadístico de regresión lineal simple entre el modelo Deep learning y el sistema de selección de contratistas en el sector minero, además el modelo Deep Learning ha demostrado ser capaz de generar resultados cercanos a las evaluaciones realizadas por el comité de la empresa minera, esta consistencia es muy prometedora, ya que indica que el modelo puede identificar patrones y características importantes en los expedientes de los contratistas, permitiendo hacer recomendaciones acertadas.

Se concluye que existe influencia significativa y positiva (0,965; sig. 0,000) según el estadístico de regresión lineal simple entre el modelo Deep learning y la cartera de clientes de los contratistas en el sector minero, por tanto la concordancia entre los resultados del modelo y las evaluaciones realizadas a la cartera de clientes de los contratistas, resalta como una evidencia la efectividad y utilidad del modelo Deep Learning en el análisis de la relación comercial con otras empresas en la gestión de la cartera de clientes del sistema de selección de contratistas del sector minero.

Se concluye que existe influencia significativa y positiva (0,941; sig. 0,000) según el estadístico de regresión lineal simple entre el modelo Deep learning y la evaluación crediticia de los contratistas en el sector minero, por ello el Modelo Deep Learning muestra un rendimiento sobresaliente al aproximarse significativamente a las decisiones tomadas por el comité evaluador, destacando la efectividad y precisión en el análisis de la salud crediticia en términos de riesgo dentro de la evaluación crediticia del sistema de selección de contratistas del sector minero.

Se concluye que existe influencia significativa y positiva (0,997; sig. 0,000) según el estadístico de regresión lineal simple entre el modelo Deep learning y la experiencia real de los contratistas en el sector minero, siendo el Modelo Deep Learning excepcional al demostrar un alto rendimiento en la evaluación del contratista, resaltándose la efectividad y precisión del modelo en el análisis de los servicios relacionados con su experiencia real en el sistema de selección de contratistas del sector minero, permitiendo mejorar y agilizar los procesos de selección en la industria con eficiencia y calidad en las decisiones tomadas para la adquisición de servicios de contratistas.

8. FUENTES DE INFORMACIÓN

- Arh, T., & Blažič, B. J. (2008). A Case Study of Usability Testing—The SUMI Evaluation Approach of the EducaNext Portal. *WSEAS Transactions on Information Science & Applications*, 5(2), 175–181.
- Hayat, H., Lock, R., & Murray, I. (2015). Measuring Software Usability. *Software Quality Management Conference*, 10.

- ISO. (2010). ISO 9241-210:2010 Ergonomics of human–system interaction—Human-centred design for interactive systems. En *International Organization for Standardization*. <https://doi.org/10.1039/c0dt90114h>
- ISO. (2011). *ISO 26800:2011—Ergonomics—General approach, principles and concepts*. International Standards Organisation. <https://www.iso.org/standard/42885.html>
- ISO/IEC. (2012). ISO/IEC 20000-2:2012(en) Information technology—Service management—Part 2: Guidance on the application of service management systems. En *International Organization for Standardization*.
- Weheba, G., Attar, M., & Salha, M. (2017). A Usability Assessment of a Statistical Analysis software Package. *Management and Engineering Integration*, 10(2), 2017.
- Maqsoom, A., Bajwa, S., & Zahoor, H. (2019). Optimizing contractor’s selection and bid evaluation process in construction industry: Client’s perspective. 445-458. doi:doi:10.30827/rconst.v18n3.7248451
- Maqsoom, A., Bajwa, S., Zahoor, H., Deakin University, Dawood, M., (2019). *Optimizing contractor’s selection and bid evaluation process in construction industry: Client’s perspective*. Revista de La Construcción, 18(3), 445–458. <https://doi.org/10.7764/RDLC.18.3.445>
- Rojas, J., & Rojas, M. (2018). Selección de contratistas en la industria minera de Chile: una aproximación desde la teoría de juegos. 111-120. doi:doi:10.5565/rev_ing.ind.v30n2.2018006
- Sagástegui Plate, D. E. (2020). Calidad en las Empresas en el Sector Minería del Perú.
- Sanchez, C. (2020). *Normas APA (7ma edición)* (Vol. 7ma edición). Madrid: Universidad Complutense de Madrid.
- Creswell, J. W., & Creswell, J. D. (2018). *Research design: Qualitative, quantitative, and mixed methods approaches (5th ed.)*. SAGE Publications.
- Fraenkel, J. R., Wallen, N. E., & Hyun, H. H. (2022). *How to design and evaluate research in education (10th ed.)*. McGraw-Hill.
- Hernández-Sampieri, R., & Mendoza, C. (2018). *Metodología de la investigación (6th ed.)*. McGraw-Hill.
- Popper, K. (2008). *The logic of scientific discovery*. Routledge.
- Babbie, E. R. (2018). *The practice of social research (15th ed.)*. Cengage Learning.

ANEXOS

Anexo 1. Matriz de consistencia

Título de tesis: Modelo deep learning en el sistema de selección de contratistas en el sector minero, Tacna 2023

PROBLEMA GENERAL	OBJETIVO GENERAL	HIPÓTESIS GENERAL	VARIABLES	METODOLOGÍA
¿Cuál será la influencia del modelo Deep learning en el sistema de selección de contratistas en el sector minero, Tacna 2023?	Determinar la influencia del modelo Deep learning en el sistema de selección de contratistas en el sector minero, Tacna 2023	Existe influencia del modelo Deep learning en el sistema de selección de contratistas en el sector minero, Tacna 2023	Variable X Deep learning Dimensiones: <ul style="list-style-type: none"> • Clasificación por redes neuronales artificiales multiclase • Clasificación por algoritmos de recomendación • Clasificación por algoritmo transformer Variable Y Sistema de selección de contratistas Dimensiones: <ul style="list-style-type: none"> • Cartera de clientes • Evaluación crediticia • Experiencia real 	Tipo de investigación: Aplicada Nivel de investigación: Descriptiva y Explicativa Método: Hipotético Deductivo Diseño de investigación: Experimental, longitudinal y preexperimental Población: 213 expedientes de contratistas. Muestra: 213 expedientes de contratistas Técnicas: -Observación -Análisis documental Instrumentos: -Guía de observación -Ficha de recolección de datos - Prueba paramétrica regresión lineal simple
PROBLEMAS ESPECIFICOS	OBJETIVOS ESPECÍFICOS	HIPÓTESIS ESPECIFICOS		
¿Cuál será la influencia del modelo Deep learning en la Cartera de Clientes de los contratistas en el sector minero, Tacna 2023?	Especificar la influencia del modelo Deep learning en la Cartera de Clientes de los contratistas en el sector minero, Tacna 2023	Existe influencia del modelo Deep learning en la Cartera de Clientes de los contratistas en el sector minero, Tacna 2023		
¿Cuál será la influencia del modelo Deep learning en la Evaluación crediticia de los contratistas en el sector minero, Tacna 2023?	Evaluar la influencia del modelo Deep learning en la Evaluación crediticia de los contratistas en el sector minero, Tacna 2023	Existe influencia del modelo Deep learning en la Evaluación crediticia de los contratistas en el sector minero, Tacna 2023		
¿Cuál será la influencia del modelo Deep learning en la Experiencia real de los contratistas en el sector minero, Tacna 2023?	Demostrar la influencia del modelo Deep learning en la Experiencia real de los contratistas en el sector minero, Tacna 2023.	Existe influencia del modelo Deep learning en la Experiencia real de los contratistas en el sector minero, Tacna 2023		

Anexo 2. Instrumentos de recolección de datos

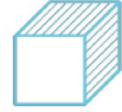
Instrumento del Modelo deep learning (VI)

Guía de observación del Modelo deep learning					
1. Información del observador Nombre del observador: Fecha: Hora: Ubicación:					
2. Escala de valoración -Muy malo [0 - 49] -Malo [50 - 84] -Bueno [85 - 100]					
3. Observación Se registra el resultado de la precisión de clasificación obtenida por las dimensiones / indicadores del modelo deep learning.					
Dimensión	Clasificación por redes neuronales artificiales multiclase	Clasificación por algoritmos de recomendación	Clasificación por algoritmo transformer	Mejor resultado de clasificación	
Indicador	Precisión de la clasificación	Precisión de la clasificación	Precisión de la clasificación		
Observaciones	Resultado	Resultado	Resultado	Mayor precisión por	Valoración
Expediente 1 (ejemplo)	45.15	60.89	90.05	Algoritmo transformer	Bueno
Expediente 2					
Expediente 3					
Expediente 4					
Expediente 5					
Expediente 6					
Expediente 7					
.....					
Expediente 213					
<i>Nota. Las observaciones de los expedientes de contratistas aplicando el modelo deep learning dará como resultado el posttest según la mayor precisión del clasificador.</i>					

Instrumento del Sistema de selección de contratistas (VD)

Ficha de recolección de datos de expedientes para el Sistema de selección de contratistas			
Licitación Nro:			
Fecha:			
Área:			
Empresa contratista:			
Dimensión/Indicador	Puntaje	Puntaje máximo	Valoración
1. Cartera de clientes			
1.1. Relación mercantil con otras empresas		10	Bajo [0 - 4] Medio [5 - 7] Alto [8 - 10]
2. Evaluación crediticia			
2.1. Salud crediticia a nivel de riesgo		10	Bajo [0 - 4] Medio [5 - 7] Alto [8 - 10]
3. Experiencia real			
3.1. Servicios relacionados		80	Bajo [0 - 27] Medio [28 - 54] Alto [55 - 80]
Total		100	Rechazado [0 - 49] Observado [50 - 84] Aceptado [85 - 100]
Observaciones:			
<i>Nota. El comité evaluador acuerda invitar a la licitación a las empresas que obtengan un puntaje total que sea igual o mayor a 85 puntos.</i>			

Anexo 3. Ficha de validación de instrumento



FICHA DE VALIDACIÓN DE INSTRUMENTO

I. DATOS GENERALES

- 1.1 **Apellidos y nombres del experto:** Dr. Anibal Fernando Flores García
- 1.2 **Grado académico:** Doctor en Ciencias de la computación
- 1.3 **Cargo e institución donde labora:** Docente de la Universidad Nacional de Moquegua
- 1.4 **Título de la Investigación:** Modelo Deep Learning en el sistema de selección de contratistas en el sector minero, Tacna 2023
- 1.5 **Autor del instrumento:** Mg. Juan Carlos Jimenez Flores
- 1.6 **Maestría/ Doctorado/ Mención:** Doctorado en Ingeniería de Sistemas
- 1.7 **Nombre del instrumento:** Modelo Deep Learning

INDICADORES	CUALITATIVOS	CRITERIOS				
		CUANTITATIVOS				
		Deficiente 0-20%	Regular 21-40%	Bueno 41-60%	Muy Bueno 61-80%	Excelente 81-100%
1. CLARIDAD	Está formulado con lenguaje apropiado.					100
2. OBJETIVIDAD	Está expresado en conductas observables.					100
3. ACTUALIDAD	Adecuado al alcance de ciencia y tecnología.					100
4. ORGANIZACIÓN	Existe una organización lógica.					100
5. SUFICIENCIA	Comprende los aspectos de cantidad y calidad.					100
6. INTENCIONALIDAD	Adecuado para valorar aspectos del estudio.					100
7. CONSISTENCIA	Basados en aspectos Teóricos-Científicos y del tema de estudio.					100
8. COHERENCIA	Entre los índices, indicadores, dimensiones y variables.					100
9. METODOLOGIA	La estrategia responde al propósito del estudio.					100
10. CONVENIENCIA	Genera nuevas pautas en la investigación y construcción de teorías.					100
SUB TOTAL						100
TOTAL						100

VALORACION CUANTITATIVA (Total x 0.20) : 20

VALORACION CUALITATIVA : Instrumento suficiente, relevante y claro para su aplicación en la investigación.

OPINIÓN DE APLICABILIDAD: Favorable para su aplicación.

Lugar y fecha: Lima 24 de abril de 2023



Firmado digitalmente por FLORES
GARCIA Anibal Fernando FAU
20449347448 soft
Motivo: Soy el autor del documento
Fecha: 24.04.2023 20:12:14 -05:00

Dr. Anibal Fernando Flores García
DNI: 04743476



FICHA DE VALIDACION DE INSTRUMENTO

I. DATOS GENERALES

- 1.1 **Apellidos y nombres del experto:** Dr. Anibal Fernando Flores García
- 1.2 **Grado académico:** Doctor en Ciencias de la computación
- 1.3 **Cargo e institución donde labora:** Docente de la Universidad Nacional de Moquegua
- 1.4 **Título de la Investigación:** Modelo Deep Learning en el sistema de selección de contratistas en el sector minero, Tacna 2023
- 1.5 **Autor del instrumento:** Mg. Juan Carlos Jimenez Flores
- 1.6 **Maestría/ Doctorado/ Mención:** Doctorado en Ingeniería de Sistemas
- 1.7 **Nombre del instrumento:** Sistema de selección de contratistas

INDICADORES	CRITERIOS CUALITATIVOS/CUANTITATIVOS	Deficiente 0-20%	Regular 21-40%	Bueno 41-60%	Muy Bueno 61-80%	Excelente 81-100%
1. CLARIDAD	Está formulado con lenguaje apropiado.					100
2. OBJETIVIDAD	Está expresado en conductas observables.					100
3. ACTUALIDAD	Adecuado al alcance de ciencia y tecnología.					100
4. ORGANIZACIÓN	Existe una organización lógica.					100
5. SUFICIENCIA	Comprende los aspectos de cantidad y calidad.					100
6. INTENCIONALIDAD	Adecuado para valorar aspectos del estudio.					100
7. CONSISTENCIA	Basados en aspectos Teóricos-Científicos y del tema de estudio.					100
8. COHERENCIA	Entre los índices, indicadores, dimensiones y variables.					100
9. METODOLOGIA	La estrategia responde al propósito del estudio.					100
10. CONVENIENCIA	Genera nuevas pautas en la investigación y construcción de teorías.					100
SUB TOTAL						100
TOTAL						100

VALORACION CUANTITATIVA (Total x 0.20) : 20

VALORACION CUALITATIVA : Instrumento suficiente, relevante y claro para su aplicación en la investigación.

OPINIÓN DE APLICABILIDAD: Favorable para su aplicación.

Lugar y fecha: Lima 24 de abril de 2023



Firmado digitalmente por FLORES
GARCIA Anibal Fernando FAU
20449347448 soft
Motivo: Soy el autor del documento
Fecha: 24.04.2023 20:12:14 -05:00

Dr. Anibal Fernando Flores García
DNI: 04743476



FICHA DE VALIDACIÓN DE INSTRUMENTO

I. DATOS GENERALES

- 1.1 **Apellidos y nombres del experto:** Dr. Juan Ubaldo Jimenez Castilla
- 1.2 **Grado académico:** Doctor en Ingeniería de Sistemas
- 1.3 **Cargo e institución donde labora:** Docente de la Universidad José Carlos Mariátegui
- 1.4 **Título de la Investigación:** Modelo Deep Learning en el sistema de selección de contratistas en el sector minero, Tacna 2023
- 1.5 **Autor del instrumento:** Mg. Juan Carlos Jimenez Flores
- 1.6 **Maestría/ Doctorado/ Mención:** Doctorado en Ingeniería de Sistemas
- 1.7 **Nombre del instrumento:** Modelo Deep Learning

INDICADORES	CRITERIOS				
	CUALITATIVOS	CUANTITATIVOS			
		Deficiente 0-20%	Regular 21-40%	Bueno 41-60%	Muy Bueno 61-80%
1. CLARIDAD	Está formulado con lenguaje apropiado.				100
2. OBJETIVIDAD	Está expresado en conductas observables.				100
3. ACTUALIDAD	Adecuado al alcance de ciencia y tecnología.				100
4. ORGANIZACIÓN	Existe una organización lógica.				100
5. SUFICIENCIA	Comprende los aspectos de cantidad y calidad.				100
6. INTENCIONALIDAD	Adecuado para valorar aspectos del estudio.				100
7. CONSISTENCIA	Basados en aspectos Teóricos-Científicos y del tema de estudio.				100
8. COHERENCIA	Entre los índices, indicadores, dimensiones y variables.				100
9. METODOLOGIA	La estrategia responde al propósito del estudio.				100
10. CONVENIENCIA	Genera nuevas pautas en la investigación y construcción de teorías.				100
SUB TOTAL					100
TOTAL					100

VALORACION CUANTITATIVA (Total x 0.20) : 20

VALORACION CUALITATIVA : Instrumento claro y relevante para la investigación, que cumple con todos los indicadores.

OPINIÓN DE APLICABILIDAD: Favorable para su aplicación.

Lugar y fecha: Lima 25 de abril de 2023



Dr. Juan Ubaldo Jimenez Castilla
DNI: 00486572



FICHA DE VALIDACION DE INSTRUMENTO

I. DATOS GENERALES

- 1.1 **Apellidos y nombres del experto:** Dr. Juan Ubaldo Jimenez Castilla
- 1.2 **Grado académico:** Doctor en Ingeniería de Sistemas
- 1.3 **Cargo e institución donde labora:** Docente de la Universidad José Carlos Mariátegui
- 1.4 **Título de la Investigación:** Modelo Deep Learning en el sistema de selección de contratistas en el sector minero, Tacna 2023
- 1.5 **Autor del instrumento:** Mg. Juan Carlos Jimenez Flores
- 1.6 **Maestría/ Doctorado/ Mención:** Doctorado en Ingeniería de Sistemas
- 1.7 **Nombre del instrumento:** Sistema de selección de contratistas

INDICADORES	CRITERIOS CUALITATIVOS/CUANTITATIVOS	Deficiente 0-20%	Regular 21-40%	Bueno 41-60%	Muy Bueno 61-80%	Excelente 81-100%
1. CLARIDAD	Está formulado con lenguaje apropiado.					100
2. OBJETIVIDAD	Está expresado en conductas observables.					100
3. ACTUALIDAD	Adecuado al alcance de ciencia y tecnología.					100
4. ORGANIZACIÓN	Existe una organización lógica.					100
5. SUFICIENCIA	Comprende los aspectos de cantidad y calidad.					100
6. INTENCIONALIDAD	Adecuado para valorar aspectos del estudio.					100
7. CONSISTENCIA	Basados en aspectos Teóricos-Científicos y del tema de estudio.					100
8. COHERENCIA	Entre los índices, indicadores, dimensiones y variables.					100
9. METODOLOGIA	La estrategia responde al propósito del estudio.					100
10. CONVENIENCIA	Genera nuevas pautas en la investigación y construcción de teorías.					100
SUB TOTAL						100
TOTAL						100

VALORACION CUANTITATIVA (Total x 0.20) : 20

VALORACION CUALITATIVA : Instrumento claro y relevante para la investigación, que cumple con todos los indicadores.

OPINIÓN DE APLICABILIDAD: Aplicable para la investigación.

Lugar y fecha: Lima 25 de abril de 2023

.....
Dr. Juan Ubaldo Jimenez Castilla
DNI: 00486572



FICHA DE VALIDACIÓN DE INSTRUMENTO

I. DATOS GENERALES

- 1.1 **Apellidos y nombres del experto:** Dr. Otoniel Silva Delgado
- 1.2 **Grado académico:** Doctor en Ingeniería de Sistemas
- 1.3 **Cargo e institución donde labora:** Docente de la Universidad José Carlos Mariátegui
- 1.4 **Título de la Investigación:** Modelo Deep Learning en el sistema de selección de contratistas en el sector minero, Tacna 2023
- 1.5 **Autor del instrumento:** Mg. Juan Carlos Jimenez Flores
- 1.6 **Maestría/ Doctorado/ Mención:** Doctorado en Ingeniería de Sistemas
- 1.7 **Nombre del instrumento:** Modelo Deep Learning

INDICADORES	CUALITATIVOS	CRITERIOS				
		CUANTITATIVOS				
		Deficiente 0-20%	Regular 21-40%	Bueno 41-60%	Muy Bueno 61-80%	Excelente 81-100%
1. CLARIDAD	Está formulado con lenguaje apropiado.					100
2. OBJETIVIDAD	Está expresado en conductas observables.					100
3. ACTUALIDAD	Adecuado al alcance de ciencia y tecnología.					100
4. ORGANIZACIÓN	Existe una organización lógica.					100
5. SUFICIENCIA	Comprende los aspectos de cantidad y calidad.					100
6. INTENCIONALIDAD	Adecuado para valorar aspectos del estudio.					100
7. CONSISTENCIA	Basados en aspectos Teóricos-Científicos y del tema de estudio.					100
8. COHERENCIA	Entre los índices, indicadores, dimensiones y variables.					100
9. METODOLOGIA	La estrategia responde al propósito del estudio.					100
10. CONVENIENCIA	Genera nuevas pautas en la investigación y construcción de teorías.					100
SUB TOTAL						100
TOTAL						100

VALORACION CUANTITATIVA (Total x 0.20) : 20

VALORACION CUALITATIVA : El instrumento cumple con los criterios e indicadores de evaluación.

OPINIÓN DE APLICABILIDAD: Es aplicable el instrumento para la investigación.

Lugar y fecha: Lima 25 de abril de 2023

.....
Dr. Otoniel Silva Delgado
DNI: 16668076



FICHA DE VALIDACIÓN DE INSTRUMENTO

I. DATOS GENERALES

- 1.1 **Apellidos y nombres del experto:** Dr. Otoniel Silva Delgado
- 1.2 **Grado académico:** Doctor en Ingeniería de Sistemas
- 1.3 **Cargo e institución donde labora:** Docente de la Universidad José Carlos Mariátegui
- 1.4 **Título de la Investigación:** Modelo Deep Learning en el sistema de selección de contratistas en el sector minero, Tacna 2023
- 1.5 **Autor del instrumento:** Mg. Juan Carlos Jimenez Flores
- 1.6 **Maestría/ Doctorado/ Mención:** Doctorado en Ingeniería de Sistemas
- 1.7 **Nombre del instrumento:** Sistema de selección de contratistas

INDICADORES	CRITERIOS CUALITATIVOS/CUANTITATIVOS	Deficiente 0-20%	Regular 21-40%	Bueno 41-60%	Muy Bueno 61-80%	Excelente 81-100%
1. CLARIDAD	Está formulado con lenguaje apropiado.					100
2. OBJETIVIDAD	Está expresado en conductas observables.					100
3. ACTUALIDAD	Adecuado al alcance de ciencia y tecnología.					100
4. ORGANIZACIÓN	Existe una organización lógica.					100
5. SUFICIENCIA	Comprende los aspectos de cantidad y calidad.					100
6. INTENCIONALIDAD	Adecuado para valorar aspectos del estudio.					100
7. CONSISTENCIA	Basados en aspectos Teóricos-Científicos y del tema de estudio.					100
8. COHERENCIA	Entre los índices, indicadores, dimensiones y variables.					100
9. METODOLOGIA	La estrategia responde al propósito del estudio.					100
10. CONVENIENCIA	Genera nuevas pautas en la investigación y construcción de teorías.					100
SUB TOTAL						100
TOTAL						100

VALORACION CUANTITATIVA (Total x 0.20) : 20

VALORACION CUALITATIVA : El instrumento cumple con los criterios e indicadores de evaluación.

OPINIÓN DE APLICABILIDAD: Es aplicable el instrumento para la investigación.

Lugar y fecha: Lima 25 de abril de 2023

Dr. Otoniel Silva Delgado
DNI: 16668076

Anexo 4. Copia de la data procesada

CONTRATISTA	CODIGO	PROYECTO	Expedientes	Sin Deep Learning			Total Pretest	Aplicando Deep Learning			
				D1 ly1	D2 ly2	D3 ly3		D1 ly1	D2 ly2	D3 ly3	Total Posttest
1001	E-101	ELECTRICIDAD	1	9	8	0	17	9	9	0	18
1002	E-102	ELECTRICIDAD	2	9	7	27	43	9	7	30	46
1003	E-103	ELECTRICIDAD	3	5	4	15	24	5	4	18	27
1004	E-104	ELECTRICIDAD	4	8	2	78	88	8	2	80	90
1005	E-105	ELECTRICIDAD	5	2	0	73	75	2	0	76	78
1006	E-106	ELECTRICIDAD	6	1	6	70	77	1	8	70	79
1007	E-107	ELECTRICIDAD	7	9	7	77	93	10	7	77	94
1008	E-108	ELECTRICIDAD	8	3	1	8	12	3	1	8	12
1009	E-109	ELECTRICIDAD	9	3	9	77	89	3	9	78	90
1010	E-110	ELECTRICIDAD	10	0	5	34	39	0	5	34	39
1011	E-111	ELECTRICIDAD	11	2	0	64	66	2	0	65	67
1012	E-112	ELECTRICIDAD	12	2	0	27	29	2	0	27	29
1013	E-113	ELECTRICIDAD	13	6	0	1	7	7	0	1	8
1014	E-114	ELECTRICIDAD	14	2	1	12	15	3	1	13	17
1015	E-115	ELECTRICIDAD	15	1	4	11	16	1	4	12	17
1016	E-116	ELECTRICIDAD	16	1	5	5	11	1	5	5	11
1017	E-117	ELECTRICIDAD	17	5	8	5	18	6	8	5	19
1018	E-118	ELECTRICIDAD	18	1	4	75	80	1	4	77	82
1019	E-119	ELECTRICIDAD	19	5	10	0	15	5	10	0	15
1020	E-120	ELECTRICIDAD	20	6	4	19	29	6	4	19	29
1021	CC-121	CONSTRUCCION_CIVIL	21	3	9	25	37	3	9	26	38
1022	CC-122	CONSTRUCCION_CIVIL	22	6	6	34	46	7	6	34	47
1023	CC-123	CONSTRUCCION_CIVIL	23	8	1	78	87	8	1	80	89
1024	CC-124	CONSTRUCCION_CIVIL	24	10	2	70	82	10	2	70	82
1025	CC-125	CONSTRUCCION_CIVIL	25	7	6	28	41	7	6	28	41
1026	CC-126	CONSTRUCCION_CIVIL	26	9	9	34	52	9	10	34	53
1027	CC-127	CONSTRUCCION_CIVIL	27	2	7	78	87	2	7	78	87
1028	CC-128	CONSTRUCCION_CIVIL	28	3	5	31	39	3	5	31	39
1029	CC-129	CONSTRUCCION_CIVIL	29	5	4	72	81	5	4	73	82
1030	CC-130	CONSTRUCCION_CIVIL	30	9	9	19	37	9	9	19	37
1031	CC-131	CONSTRUCCION_CIVIL	31	6	6	8	20	6	6	8	20
1032	CC-132	CONSTRUCCION_CIVIL	32	1	4	73	78	1	4	74	79
1033	CC-133	CONSTRUCCION_CIVIL	33	3	1	42	46	3	1	42	46
1034	CC-134	CONSTRUCCION_CIVIL	34	7	1	2	10	7	1	2	10
1035	CC-135	CONSTRUCCION_CIVIL	35	2	5	9	16	2	5	9	16
1036	CC-136	CONSTRUCCION_CIVIL	36	8	7	29	44	8	7	29	44
1037	CC-137	CONSTRUCCION_CIVIL	37	3	2	20	25	3	2	20	25
1038	CC-138	CONSTRUCCION_CIVIL	38	4	8	39	51	4	8	39	51
1039	CC-139	CONSTRUCCION_CIVIL	39	7	6	30	43	7	6	30	43
1040	CC-140	CONSTRUCCION_CIVIL	40	9	8	59	76	9	10	59	78
1041	CC-141	CONSTRUCCION_CIVIL	41	5	9	70	84	5	10	70	85
1042	CC-142	CONSTRUCCION_CIVIL	42	6	0	62	68	6	0	62	68
1043	CC-143	CONSTRUCCION_CIVIL	43	6	4	4	14	7	4	4	15
1044	CC-144	CONSTRUCCION_CIVIL	44	8	7	5	20	8	7	5	20
1045	CC-145	CONSTRUCCION_CIVIL	45	1	1	44	46	1	1	44	46
1046	CC-146	CONSTRUCCION_CIVIL	46	9	9	89	107	9	9	80	98
1047	CC-147	CONSTRUCCION_CIVIL	47	4	9	71	84	4	9	71	84
1048	CC-148	CONSTRUCCION_CIVIL	48	10	1	17	28	10	1	17	28
1049	CC-149	CONSTRUCCION_CIVIL	49	4	4	36	44	4	4	37	45
1050	CC-150	CONSTRUCCION_CIVIL	50	5	9	6	20	5	9	6	20
1051	CC-151	CONSTRUCCION_CIVIL	51	10	0	32	42	10	0	32	42
1052	CC-152	CONSTRUCCION_CIVIL	52	8	5	47	60	8	5	48	61
1053	CC-153	CONSTRUCCION_CIVIL	53	5	2	40	47	5	2	40	47
1054	CC-154	CONSTRUCCION_CIVIL	54	8	9	0	17	8	10	0	18
1055	CC-155	CONSTRUCCION_CIVIL	55	2	9	77	88	2	9	77	88
1056	CC-156	CONSTRUCCION_CIVIL	56	6	6	56	68	7	6	56	69
1057	CC-157	CONSTRUCCION_CIVIL	57	8	9	78	95	8	9	78	95
1058	CC-158	CONSTRUCCION_CIVIL	58	2	10	58	70	2	10	58	70
1059	CC-159	CONSTRUCCION_CIVIL	59	6	8	71	85	6	8	71	85
1060	CC-160	CONSTRUCCION_CIVIL	60	7	9	48	64	7	9	50	66
1061	CC-161	CONSTRUCCION_CIVIL	61	2	3	15	20	2	3	15	20
1062	CC-162	CONSTRUCCION_CIVIL	62	8	0	66	74	8	0	67	75
1063	CC-163	CONSTRUCCION_CIVIL	63	9	1	48	58	9	1	48	58
1064	CC-164	CONSTRUCCION_CIVIL	64	5	9	45	59	5	9	45	59
1065	CC-165	CONSTRUCCION_CIVIL	65	9	2	5	16	9	2	5	16

1066	CC-166	CONSTRUCCION_CIVIL	66	9	5	56	70	10	5	56	71
1067	CC-167	CONSTRUCCION_CIVIL	67	9	3	12	24	10	3	12	25
1068	CC-168	CONSTRUCCION_CIVIL	68	4	1	55	60	4	1	55	60
1069	CC-169	CONSTRUCCION_CIVIL	69	8	6	24	38	8	6	24	38
1070	CC-170	CONSTRUCCION_CIVIL	70	2	8	64	74	2	8	64	74
1071	CC-171	CONSTRUCCION_CIVIL	71	6	1	49	56	6	1	49	56
1072	CC-172	CONSTRUCCION_CIVIL	72	6	0	1	7	6	0	1	7
1073	CC-173	CONSTRUCCION_CIVIL	73	0	9	79	88	0	9	79	88
1074	CC-174	CONSTRUCCION_CIVIL	74	0	9	58	67	0	10	58	68
1075	CC-175	CONSTRUCCION_CIVIL	75	7	7	5	19	7	7	5	19
1076	CC-176	CONSTRUCCION_CIVIL	76	10	7	8	25	10	7	8	25
1077	CC-177	CONSTRUCCION_CIVIL	77	1	1	57	59	1	1	58	60
1078	CC-178	CONSTRUCCION_CIVIL	78	5	2	49	56	5	2	49	56
1079	CC-179	CONSTRUCCION_CIVIL	79	2	10	65	77	2	10	66	78
1080	CC-180	CONSTRUCCION_CIVIL	80	8	5	7	20	8	5	7	20
1081	CC-181	CONSTRUCCION_CIVIL	81	8	10	41	59	8	10	41	59
1082	CC-182	CONSTRUCCION_CIVIL	82	8	6	38	52	8	6	39	53
1083	CC-183	CONSTRUCCION_CIVIL	83	2	2	65	69	2	2	65	69
1084	CC-184	CONSTRUCCION_CIVIL	84	0	0	60	60	0	0	60	60
1085	CC-185	CONSTRUCCION_CIVIL	85	10	4	65	79	10	4	66	80
1086	CC-186	CONSTRUCCION_CIVIL	86	10	6	21	37	10	6	21	37
1087	CC-187	CONSTRUCCION_CIVIL	87	6	4	45	55	6	4	46	56
1088	CC-188	CONSTRUCCION_CIVIL	88	5	0	7	12	5	0	7	12
1089	CC-189	CONSTRUCCION_CIVIL	89	8	1	22	31	8	1	22	31
1090	CC-190	CONSTRUCCION_CIVIL	90	4	5	45	54	4	5	46	55
1091	CC-191	CONSTRUCCION_CIVIL	91	3	8	15	26	3	8	15	26
1092	CC-192	CONSTRUCCION_CIVIL	92	9	3	9	21	10	3	9	22
1093	V-193	MISCELANEOS	93	9	2	25	36	9	2	26	37
1094	V-194	MISCELANEOS	94	2	8	44	54	2	8	44	54
1095	V-195	MISCELANEOS	95	6	7	60	73	7	7	60	74
1096	V-196	MISCELANEOS	96	4	0	8	12	4	0	8	12
1097	V-197	MISCELANEOS	97	2	8	49	59	2	8	49	59
1098	V-198	MISCELANEOS	98	2	0	36	38	2	0	36	38
1099	V-199	MISCELANEOS	99	8	1	50	59	8	1	52	61
1100	V-200	MISCELANEOS	100	4	8	9	21	4	8	9	21
1101	V-201	MISCELANEOS	101	4	9	13	26	4	9	14	27
1102	V-202	MISCELANEOS	102	7	2	58	67	7	2	58	67
1103	V-203	MISCELANEOS	103	6	7	22	35	6	8	22	36
1104	V-204	MISCELANEOS	104	8	7	42	57	8	7	42	57
1105	V-205	MISCELANEOS	105	8	6	10	24	9	6	10	25
1106	V-206	MISCELANEOS	106	0	9	19	28	0	9	19	28
1107	V-207	MISCELANEOS	107	1	7	69	77	1	8	69	78
1108	V-208	MISCELANEOS	108	0	0	49	49	0	0	49	49
1109	V-209	MISCELANEOS	109	4	5	26	35	4	5	26	35
1110	V-210	MISCELANEOS	110	1	1	40	42	1	1	40	42
1111	V-211	MISCELANEOS	111	4	5	44	53	4	5	44	53
1112	V-212	MISCELANEOS	112	6	7	40	53	7	7	40	54
1113	V-213	MISCELANEOS	113	6	3	64	73	6	3	65	74
1114	V-214	MISCELANEOS	114	8	0	78	86	8	0	78	86
1115	V-215	MISCELANEOS	115	3	3	3	9	4	3	3	10
1116	V-216	MISCELANEOS	116	2	3	67	72	2	3	67	72
1117	V-217	MISCELANEOS	117	2	8	53	63	2	8	54	64
1118	V-218	MISCELANEOS	118	6	3	33	42	7	3	33	43
1119	V-219	MISCELANEOS	119	2	3	74	79	2	4	74	80
1120	V-220	MISCELANEOS	120	7	6	42	55	7	7	42	56
1141	MM-241	METAL_MECANICA	121	4	8	51	63	4	8	52	64
1142	MM-242	METAL_MECANICA	122	5	5	18	28	5	6	18	29
1143	MM-243	METAL_MECANICA	123	5	5	24	34	6	5	24	35
1144	MM-244	METAL_MECANICA	124	5	7	8	20	5	7	8	20
1145	MM-245	METAL_MECANICA	125	9	9	36	54	9	10	36	55
1146	MM-246	METAL_MECANICA	126	4	3	54	61	4	4	53	61
1147	MM-247	METAL_MECANICA	127	9	6	7	22	9	6	7	22
1148	MM-248	METAL_MECANICA	128	10	9	67	86	10	10	68	88
1149	MM-249	METAL_MECANICA	129	6	10	32	48	6	10	34	50
1150	MM-250	METAL_MECANICA	130	2	4	38	44	2	4	40	46
1151	MM-251	METAL_MECANICA	131	1	8	43	52	1	9	43	53
1152	MM-252	METAL_MECANICA	132	7	9	53	69	7	10	54	71
1153	MM-253	METAL_MECANICA	133	7	7	20	34	8	8	20	36
1154	MM-254	METAL_MECANICA	134	2	2	58	62	3	2	58	63
1155	MM-255	METAL_MECANICA	135	0	0	70	70	0	0	71	71
1156	MM-256	METAL_MECANICA	136	5	7	76	88	5	7	77	89
1157	MM-257	METAL_MECANICA	137	2	5	71	78	2	6	71	79
1158	MM-258	METAL_MECANICA	138	0	5	67	72	0	5	68	73
1159	MM-259	METAL_MECANICA	139	0	2	42	44	0	2	42	44
1160	MM-260	METAL_MECANICA	140	4	0	39	43	4	0	39	43
1161	MM-261	METAL_MECANICA	141	7	6	46	59	7	7	46	60
1162	MM-262	METAL_MECANICA	142	2	8	54	64	2	8	55	65
1163	MM-263	METAL_MECANICA	143	3	5	67	75	3	6	67	76
1164	MM-264	METAL_MECANICA	144	1	1	39	41	1	1	39	41
1165	MM-265	METAL_MECANICA	145	0	9	10	19	0	10	10	20
1166	MM-266	METAL_MECANICA	146	4	7	53	64	4	8	53	65
1167	MM-267	METAL_MECANICA	147	6	5	7	18	6	5	7	18
1168	MM-268	METAL_MECANICA	148	8	4	48	60	9	4	48	61

1169	MM-269	METAL_MECANICA	149	7	9	1	17	7	9	1	17
1170	MM-270	METAL_MECANICA	150	5	3	45	53	5	3	46	54
1171	MM-271	METAL_MECANICA	151	4	2	5	11	4	2	5	11
1172	MM-272	METAL_MECANICA	152	0	7	49	56	0	8	49	57
1173	MM-273	METAL_MECANICA	153	6	7	47	60	6	8	47	61
1174	MM-274	METAL_MECANICA	154	3	3	38	44	3	3	38	44
1175	MM-275	METAL_MECANICA	155	8	1	20	29	8	1	20	29
1176	MM-276	METAL_MECANICA	156	0	6	14	20	0	6	15	21
1177	MM-277	METAL_MECANICA	157	0	1	25	26	0	1	25	26
1178	MM-278	METAL_MECANICA	158	2	2	73	77	2	2	74	78
1179	MM-279	METAL_MECANICA	159	6	6	37	49	6	6	37	49
1180	MM-280	METAL_MECANICA	160	0	6	62	68	0	6	62	68
1181	MM-281	METAL_MECANICA	161	7	0	66	73	7	0	66	73
1182	MM-282	METAL_MECANICA	162	6	8	68	82	6	9	68	83
1183	MM-283	METAL_MECANICA	163	2	0	53	55	2	0	54	56
1184	MM-284	METAL_MECANICA	164	0	9	17	26	0	9	17	26
1185	MM-285	METAL_MECANICA	165	7	3	76	86	8	3	76	87
1186	MM-286	METAL_MECANICA	166	7	3	80	90	7	3	80	90
1187	MM-287	METAL_MECANICA	167	4	8	60	72	4	10	60	74
1188	MM-288	METAL_MECANICA	168	1	0	77	78	1	0	78	79
1189	MM-289	METAL_MECANICA	169	6	5	26	37	6	5	26	37
1190	MM-290	METAL_MECANICA	170	9	5	37	51	10	5	37	52
1191	MM-291	METAL_MECANICA	171	1	7	69	77	1	7	69	77
1192	MM-292	METAL_MECANICA	172	8	5	64	77	8	6	64	78
1193	MM-293	METAL_MECANICA	173	5	7	78	90	5	8	78	91
1194	MM-294	METAL_MECANICA	174	5	0	44	49	5	0	45	50
1195	MM-295	METAL_MECANICA	175	2	8	72	82	2	9	72	83
1196	MM-296	METAL_MECANICA	176	6	2	47	55	6	2	47	55
1197	MM-297	METAL_MECANICA	177	6	9	38	53	6	10	38	54
1198	MM-298	METAL_MECANICA	178	0	1	21	22	0	1	21	22
1199	MM-299	METAL_MECANICA	179	7	3	47	57	7	3	48	58
1200	MM-300	METAL_MECANICA	180	0	9	62	71	0	10	62	72
1201	MM-301	METAL_MECANICA	181	0	7	33	40	0	7	34	41
1202	MM-302	METAL_MECANICA	182	4	1	7	12	5	1	7	13
1203	MM-303	METAL_MECANICA	183	2	9	77	88	2	10	76	88
1204	MM-304	METAL_MECANICA	184	5	4	73	82	5	4	74	83
1205	MM-305	METAL_MECANICA	185	9	6	7	22	9	6	7	22
1206	MM-306	METAL_MECANICA	186	2	8	58	68	2	10	58	70
1207	MM-307	METAL_MECANICA	187	8	9	14	31	8	10	14	32
1208	MM-308	METAL_MECANICA	188	9	7	8	24	10	8	8	26
1209	MM-309	METAL_MECANICA	189	9	8	34	51	10	8	34	52
1210	MM-310	METAL_MECANICA	190	7	7	59	73	8	8	59	75
1211	MM-311	METAL_MECANICA	191	7	1	52	60	7	1	52	60
1212	MM-312	METAL_MECANICA	192	4	9	44	57	4	9	45	58
1213	MM-313	METAL_MECANICA	193	2	0	30	32	2	0	30	32
1214	MM-314	METAL_MECANICA	194	3	1	37	41	3	1	38	42
1215	MM-315	METAL_MECANICA	195	4	9	59	72	4	9	59	72
1216	MM-316	METAL_MECANICA	196	4	6	73	83	5	6	73	84
1217	MM-317	METAL_MECANICA	197	3	4	16	23	3	4	16	23
1218	MM-318	METAL_MECANICA	198	10	1	67	78	10	1	69	80
1219	MM-319	METAL_MECANICA	199	8	6	77	91	8	6	77	91
1220	MM-320	METAL_MECANICA	200	3	0	64	67	3	1	64	68
1221	MM-321	METAL_MECANICA	201	2	1	40	43	2	1	40	43
1222	MM-322	METAL_MECANICA	202	2	0	57	59	2	1	57	60
1223	MM-323	METAL_MECANICA	203	9	4	34	47	10	4	34	48
1224	MM-324	METAL_MECANICA	204	5	2	18	25	6	2	18	26
1225	MM-325	METAL_MECANICA	205	8	9	60	77	8	9	61	78
1226	MM-326	METAL_MECANICA	206	1	5	18	24	1	5	18	24
1227	MM-327	METAL_MECANICA	207	2	2	24	28	2	2	26	30
1228	MM-328	METAL_MECANICA	208	8	3	7	18	8	3	7	18
1229	MM-329	METAL_MECANICA	209	3	5	23	31	3	5	25	33
1230	MM-330	METAL_MECANICA	210	4	7	0	11	4	7	0	11
1231	MM-331	METAL_MECANICA	211	7	7	6	20	7	8	6	21
1232	MM-332	METAL_MECANICA	212	4	2	17	23	4	2	17	23
1233	MM-333	METAL_MECANICA	213	6	9	56	71	6	9	59	74

Anexo 5. Consentimiento informado

Título del estudio: Modelo Deep Learning en el sistema de selección de contratistas en el sector minero, Tacna 2023

Propósito del estudio:

Invitamos a usted, en su condición de miembro del comité evaluador de expedientes de contratistas a participar del trabajo de investigación: Modelo Deep Learning en el sistema de selección de contratistas en el sector minero, Tacna 2023, en el marco de estudios de Doctorado en Ingeniería de Sistemas de la Universidad Alas Peruanas, cuyo propósito es describir y explicar en que grado la variable “Modelo Deep Learning” influye en el “Sistema de selección de contratistas”.

Procedimientos: Si usted acepta participar en este estudio, realizará lo siguiente:

- Permitirá la observación sobre la “Guía de observación del Modelo Deep Learning”
- Permitirá la recolección sobre la “Ficha de recolección de datos de expedientes para el Sistema de selección de contratistas”

Riesgos: No hay riesgo alguno

Beneficios: Obtener experiencia en la participación de procesos de investigación y, posteriormente, conocer los vínculos entre las variables que se estudian en la Investigación.

Confidencialidad: Se guardará la información de manera anónima. Si los resultados del estudio son publicados, no se mostrará ninguna información concerniente a los participantes del estudio que permitan identificarlos de alguna forma.

Derechos del participante: Si decide participar del estudio, dará su “consentimiento” digitalmente al momento de completar los cuestionarios, y podrá retirarse de éste en cualquier momento o no participar en alguna parte del estudio, sin daño alguno.

DECLARACIÓN Y/O CONSENTIMIENTO

Después de haber leído el propósito de la investigación y demás información contenida en este documento, acepto participar en la investigación y brindo mi consentimiento digital desde el momento que responda a los cuestionarios.

Nombres y apellidos:

Fecha y hora:Firma:

Anexo 6. Autorización de la entidad donde se realizó el trabajo de campo



Tacna, 03 de julio del 2023

Señor (a):
JUAN CARLOS JIMENEZ FLORES
Presente.-

ASUNTO : AUTORIZACIÓN PARA INVESTIGACIÓN ACADEMICA

En atención a su solicitud para iniciar con una investigación de carácter académico, la jefatura de Contratos y Servicios autoriza la aplicación del trabajo de investigación titulado "MODELO DEEP LEARNING EN EL SISTEMA DE SELECCIÓN DE CONTRATISTAS EN EL SECTOR MINERO, TACNA 2023", con la finalidad de recabar información para el desarrollo de su trabajo.

Sin otro particular, es propicia la oportunidad para recordarle asegurar la privacidad de la información obtenida, ofuscación de datos y limitar su uso solo al marco de la investigación académica, expreso los sentimientos de mi especial consideración y estima personal.

Atentamente,

Liz Quispe Concepción
Jefe de Contratos y Servicios
SOUTHERN PERU

c.c. Archivo

Anexo 7: Declaratoria de autenticidad de la tesis



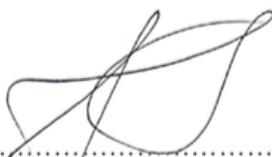
DECLARATORIA DE AUTENTICIDAD DEL INFORME FINAL DE TESIS

Yo, JUAN CARLOS JIMENEZ FLORES, identificado con DNI N° 46835580, Maestro del programa DOCTORADO EN INGENIERÍA DE SISTEMAS, de la Escuela Posgrado profesional de la Universidad Alas Peruanas, soy autor de la tesis titulada:

MODELO DEEP LEARNING EN EL SISTEMA DE SELECCIÓN DE CONTRATISTAS EN EL SECTOR MINERO, TACNA 2023

En muestra de lo cual firmo la presente declaratoria.

Lima, 31 de Junio del 2023



.....
Juan Carlos Jimenez Flores
D.N.I. N° 46835580